

DOKTORI (PhD)
ÉRTEKEZÉS

VANCSURA LÁSZLÓ

Kaposvár

2025



MAGYAR AGRÁR- ÉS ÉLETTUDOMÁNYI EGYETEM

A GÉPI TANULÁSI MODELLEK SZEREPE A GAZDASÁGI ÉS TŐZSDEI IDŐSOROK ELŐREJELZÉSÉBEN

DOI: 10.54598/005800

DOKTORI (PhD) ÉRTEKEZÉS

VANCSURA LÁSZLÓ

**Kaposvár
2025**

A doktori iskola megnevezése: Gazdaság- és Regionális Tudományok
Doktori Iskola

A doktori iskola tudományága: gazdaság- és regionális tudományok

A doktori iskola vezetője: Prof. Dr. habil Bujdosó Zoltán
egyetemi tanár
Magyar Agrár- és Élettudományi
Egyetem
Vidékfejlesztés és Fenntartható
Gazdaság Intézet

Témavezető: Dr. Bareith Tibor
tudományos munkatárs
ELTE Közgazdaság- és Regionális
Tudományi Kutatóközpont
Közgazdaságtudományi Intézet

.....
Az iskolavezető jóváhagyása

.....
A témavezető(k) jóváhagyása

TARTALOMJEGYZÉK

1. BEVEZETÉS	1
2. CÉLKITŰZÉSEK	7
3. ANYAG ÉS MÓDSZER	12
3.1. Adatok.....	12
3.2. Alkalmazott módszerek	17
3.3. Az alkalmazott szoftverek	20
3.4. A modellek értékelése	20
3.5. Volatilitás vizsgálata	21
3.5.1. STL (Seasonal-Trend decomposition using Loess)	21
3.5.2. Relatív volatilitás: variációs koefficiens (CV).....	22
3.6. Predikció alapú, dinamikusan optimalizált kereskedési stratégia	23
4. EREDMÉNYEK	26
4.1. Volatilitás vizsgálatának eredményei.....	26
4.2. Kereskedési stratégiák eredményeinek összehasonlítása	37
5. KÖVETKEZTETÉSEK ÉS JAVASLATOK	50
6. ÚJ TUDOMÁNYOS EREDMÉNYEK	56
7. ÖSSZEFOGLALÁS.....	60
8. FELHASZNÁLT SZAKIRODALOM	64
9. A TÉMAKÖRHÖZ KAPCSOLÓDÓ PUBLIKÁCIÓK	70

1. BEVEZETÉS

A tőzsde és a pénzügyi termékek iránt az érdeklődés az átlagemberek részéről az elmúlt évtizedekben exponenciálisan nőtt (Kumbure et al., 2022). A világ tőzsdéin naponta több milliárd dollár értékű eszköz cserél gazdát (Hoseinzade és Haratizadeh, 2019), a befektetők pedig azzal a szándékkal lépnek fel a piacon, hogy befektetési horizontjuk alatt nyereséget érjenek el. Ha egy magán- vagy intézményi befektető pontosan meg tudná jósolni a piac viselkedését és mozgásait, akkor ez lehetővé tenné számára, hogy magasabb kockázattal korrigált hozamot (alpha) érjen el, mint a piac. Többek között ez a tényező is motiválja a gépi tanulás és a számítógépes intelligencia módszereinek alkalmazását a tőzsdei előrejelzés minél pontosabb modelljeinek létrehozására, illetve a már meglévők finomhangolására. A részvény- és más pénzügyi piacok előrejelezhetőségét számos tanulmány vizsgálta már kifinomult előrejelző rendszerek kifejlesztésével (Sedighi et al., 2019; Song et al., 2019), közülük néhány tanulmány arról is beszámolt, hogy modelljeik komoly nyereséget tudtak termelni (Atsalakis & Valavanis, 2009a; Weng et al., 2017).

Általánosságban elmondható, hogy a tőzsdei előrejelzést a pénzügyi kutatás egyik legrelevánsabb, ugyanakkor kihívásokkal teli területeként kezelik (Chen és Hao, 2017). Mindazonáltal az a képesség, hogy egy befektető folyamatosan magasabb kockázattal korrigált hozamot ér el, mint a piac, sértheti az úgynevezett hatékony piacok hipotézisét. Fama (1970) nevéhez fűződik a piaci hatékonyság hipotézise (EMH – Efficient Market Hypothesis). Az EMH a piaci hatékonyság három formáját különbözteti meg. A gyenge formájú piaci hatékonyság azt feltételezi, hogy az idősor múltbeli áraiban szereplő információk már tükröződnek az aktuális részvényárakban is és nem segítenek a jövőbeli árfolyam-mozgások előrejelzésében (Fama, 1970). Ebből kifolyólag a technikai elemzés nem tud a várható hozam tekintetében

felülmúlni egy buy-and-hold stratégiát. A hatékony piacok hipotézisének második formája az úgynevezett félig erős piaci hatékonyság, amely azt állítja, hogy a részvényárak az összes nyilvánosan elérhető információt tükrözik (gazdasági körülmények, politikai események, kamatláb és vállalatspecifikus információk, stb.), amelyek magában foglalják a múltbeli árakra vonatkozó információkat is. Mindez arra utal, hogy a technikai elemzés eszköztárát alkalmazva sem lehet következetesen magasabb várható hozamot realizálni. A piaci hatékonyság félig erős formája esetén a nyilvánosan elérhető információk - beleértve a fundamentális adatokat is - tehát nem teszik lehetővé, hogy egy befektető felülmúlja a piacot. Ez azt jelenti, hogy az összes nyilvánosan elérhető információ birtokában az aktívan menedzselt portfóliók nem fognak következetesen magasabb kockázattal korrigált hozamot elérni, mint a passzívok, azaz a buy-and-hold stratégiát követők. Az EMH harmadik, erős formája azt állítja, hogy minden információ, beleértve a bennfentes információkat is, tükröződik a részvényárakban. Ez pedig kizárja azt, hogy bármely befektető (rendelkezzen akár bennfentes információkkal is) következetesen magasabb várható hozamot érjen el, mint a piac (Fama, 1965). Ezen okból kifolyólag az EMH erős formája gyakorlatilag azt állítja, hogy a részvénytőzsi árfolyamok alakulása, illetve a hozamok nem jelezhetők előre (Timmermann és Granger, 2004). Az EMH erős formája rendkívül szigorú kritériumokra épül, melyeket később maga Fama (1970) is részben megcáfolt, illetve finomított. Úgy fogalmazott, hogy nem várható el, hogy a bennfentes információk nem használhatók fel a magasabb várható profit realizálása érdekében.

Idővel egyre többen kérdőjelezték meg a hatékony piacok hipotézisét és azt, hogy az értékpapírok árazása racionálisan történik (Daniel et al., 1998; Borovkova és Tsiamas, 2019). Számos olyan piaci anomália létezik, amely a hatékony piacok hipotézise ellen szól (Malkiel és Mullainathan, 2005).

Ilyenek például a pénzügyi piacok túlreagálása (De Bondt és Thaler, 1985) és alulreagálása, a rövid távú lendület, a hosszú távú visszafordulás és az eszközárak magas volatilitása. Egyes kutatók az ilyen anomáliáknak a hatékony piacok hipotézisével összhangban lévő magyarázatait tárgyalták, többek között azt, hogy a túl- és alulreagálás véletlenszerűen történik és egyformán gyakori (Fama, 1998). Továbbá annak lehetőségét is vizsgálták, hogy az intézményi befektetők (smart money) képesek ellensúlyozni a kevésbé tapasztalt befektetők (dumb money) által létrehozott anomáliákat (Shiller, 2003). Ugyanakkor kétséges maradt, hogy a befektetői racionalitáson alapuló modellek képesek-e befogadni a megfigyelt anomáliákat. Mindez az emberi pszichológiát is integráló modellek felé való elmozduláshoz és a viselkedési pénzügyek megjelenéséhez vezetett, amely megkérdőjelezi a befektetők tökéletes racionalitását az olyan viselkedési torzítások miatt, mint a veszteségkerülés, a túl- és alulreagálás. Az EMH és a viselkedési pénzügyek összehangolására tett egyik kísérlet az adaptív piacok hipotézisének (AMH) javaslata volt, amely elismeri és megmagyarázza a pénzügyi piacokon tapasztalható anomáliákat (Lo, 2004).

Mivel anomáliák létezhetnek, ezért nem meglepő, hogy a piaci szereplők nagy része a múltbeli árfolyamokra vonatkozó és a vállalat-specifikus információkat (múltbeli nyereség, veszteség és profitot), valamint egyéb tényezőket használ fel a jövőbeli részvényárfolyamok becsléséhez (Patel és Marwala, 2006). A tőzsdei előrejelzési tanulmányokban általában két jól ismert elemzési megközelítést, a fundamentális elemzést és a technikai elemzést alkalmazzák (Lohrmann és Luukka, 2019; Sedighi et al., 2019). A fundamentális elemzés az alapvető információkra összpontosít. Ha a fundamentumok alapján egy vállalat részvényárfolyamát vagy hozamát prognosztizálják, akkor olyan információk kapnak szerepet, mint például a vállalat bevételei és kiadásai, éves növekedési üteme, piaci pozíciója és a pénzügyi kimutatásokban vagy

jelentésekben szereplő egyéb releváns tényezők. Egy részvényindex prognosztizálása esetén, amely számos vállalati részvényt képvisel, a piaci környezetre vonatkozó információk is bevethetők, beleértve a nemzetgazdasági termelési adatokat, a kereskedelmet, az árfolyamokat vagy a kamatlábakat, amelyek valószínűleg hatással lesznek a részvényindexben szereplő vállalatok működésére. Ezzel szemben a technikai elemzés a részvényárfolyamok és a kapcsolódó kereskedési információk (mennyiség) múltbeli alakulásának tanulmányozását jelenti a részvényárfolyamok mozgásának előrejelzése érdekében (Wei et al., 2011). A témával kapcsolatos szakirodalom alapján megállapítható, hogy számos modell áll rendelkezésre az árfolyamok, hozamok és a volatilitás előrejelzésére, melyeket a kutatók három fő csoportba sorolnak. Az elsőbe a hagyományos statisztikai, a másodikba a valamilyen mesterséges intelligencia alapú, míg a harmadikban az úgynevezett hibrid módszerek tartoznak (Kim & Won, 2018; Vidal & Kristjanpoller, 2020; Zolfaghari & Gholami, 2021).

A mesterséges intelligencia (AI) és a gépi tanulás (ML) alkalmazása alapvetően alakítja át a pénzügyi szektort, amely közvetlenül vagy közvetve, de hatással van egyéb iparágakra is. A pénzügyi szolgáltatók jelentős befektetéseketallokálnak annak érdekében, hogy fejlesszék az adattudománnyal kapcsolatos területek kiépítését és fejlesztését. A 2007-2008-as pénzügyi válság óta különösen nagy figyelmet kap az adatvezérelt innováció és szabályozás, ami a banki és kereskedelmi gyakorlatok újraértékeléséhez vezetett. Az alternatív adatok, mint például hangfelvételek és közösségi médiabejegyzések, egyre nagyobb szerepet játszanak a döntéshozatalban, azonban az ilyen adatok elemzése kihívást jelent a hagyományos megközelítések számára, ezért kerültek előtérbe a gépi tanulási modellek. Ezek az algoritmusok biztosítják a szükséges számítási teljesítményt és rugalmasságot a komplex minták feltárásához. A közelmúlt

fejlesztései lehetővé tették a tudományos elméletek hatékony alkalmazását a pontosabb előrejelzések készítése érdekében.

A legtöbb korábbi tanulmány a tőzsdei termékek előrejelzésére valamilyen statisztikai idősoros módszert alkalmazott, amely a múltbeli adatokra épített (Efendi et al., 2018). Ezek közül az autoregresszív feltételes heteroszkedaszticitás (ARCH), az autoregresszív mozgóátlag (ARMA) és az autoregresszív integrált mozgóátlag (ARIMA) modellek, a Kalman-szűrés és az exponenciális simítás a legnépszerűbb technikák (Chen & Chen, 2015; Yeh et al., 2011). Később, a mesterséges intelligencia (AI) és a soft computing megjelenésével ezek a technikák egyre nagyobb figyelmet kaptak a tőzsdei előrejelzéssel foglalkozó tanulmányokon esetében. A hagyományos idősoros módszerekkel ellentétben ezek a technikák képesek kezelni a tőzsde nemlineáris, kaotikus, zajos és összetett adatait, ami hatékonyabb előrejelzéseket eredményezhet (Chen & Hao, 2017). Ezek a módszerek innovatív és előnyös alternatívákat jelentenek, ami vonzóvá teszi őket a kutatók számára a pénzügyi piacok előrejelzéséhez. A különféle módszertanok hiányosságai hívták életre a harmadik kategóriát, amelybe az úgynevezett hibrid prediktív modellek tartoznak. Ezek kombinálják a hagyományos statisztikai és a gépi tanulás alapú módszereket a minél pontosabb becslési eredmény elérése érdekében (Reston et al., 2014; Büyüksahin és Ertekin, 2019).

Kutatásomban a legmodernebb előrejelző modelleket fogom megvizsgálni, amelyek a befektetői csoportok és vállalatok számára egyaránt fontos eszköznek számítanak a kockázatkezelés, a hozam- és a profitmaximalizálás területén. Az empirikus elemzésekhez a legnépszerűbb pénzügyi instrumentumokat, mint a részvényindexek (S&P500, DAX, Nikkei225), árupiaci termékek (nyersolaj, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) adatait gyűjtöm

össze a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. A modellek robusztusságának tesztelése szempontjából fontos, hogy ebben a periódusban megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és az orosz-ukrán konfliktus (2022) egyaránt. Mivel a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel, így többek között ez indokolta az adatbázis kezdő és végpontjainak megválasztását. A modellezéshez három mély tanulási algoritmust (RNN, LSTM, GRU), továbbá az ezekből megalkotott három hibrid módszertant (LSTM-GRU, RNN-LSTM, RNN-GRU) vizsgálok regressziós elemzéssel. A valós és becsült árfolyamok közötti eltéréseket a MAPE mutató segítségével értékelem. Az eredmények ismertetését a terméktípusok szerinti vizsgálatokkal kezdem, majd ezt követi a termékenkénti és a modelltípusonkénti összehasonlítás. Az eredmények szakasz további részében pedig az egy- és többváltozós módszerek összevetésével, az abszolút legjobb és legrosszabb prediktív teljesítményekkel és az aktivációs függvény-optimalizálás hatásaival foglalkozom. A modellek előrejelzési eredményeit továbbá felhasználom egy kereskedési stratégia kialakításához, melyet a buy-and-hold módszerrel összehasonlítok. Így a dolgozat gyakorlati gazdasági hasznosulását is igyekszem majd hangsúlyozni számszerűsíthető befektetési eredményekkel.

2. CÉLKITŰZÉSEK

A mesterséges intelligencia terjedését mi sem jelzi jobban, hogy a különféle tanuló algoritmusok szépen lassan szivárognak be az életünk különböző területeire, megkönnyítve mindennapjainkat, és hatékonyabbá téve a folyamatokat. Ennek előnyei és hátrányai természetesen még rengeteg vitaalapot generálnak majd, de úgy vélem, hogy elkerülhetetlen ezen technológiáknak az előretörése, különösen a magas tőkeerővel rendelkező iparágakban. A különféle befektetési termékek árfolyamának előrejelzése mindig kihívást jelentett a statisztikával és a pénzügyekkel foglalkozó szakembereknek egyaránt (Nabipour et al., 2020). A prediktív modellek fejlesztésének legfőbb célja, hogy a piac által generált bizonytalanságokat minél pontosabban meg lehessen becsülni, és ezáltal a kockázati tényező minimalizálhatóvá váljon.

A gépi tanulási módszertanok elterjedése, valamint egyre szélesebb körű alkalmazása hozzájárult a prediktív modellek teljesítményének javulásához és az előrejelzések pontosságának növeléséhez (Maqsood et al., 2019). A predikcióval foglalkozó szakértőknek a modellfejlesztések során alapvetően számos kihívással kell szembenézniük. A komplexitás, a zajos információk, a fejlődési sajátosságok és a nem lineáris kapcsolatok problémakörei többek között a tőzsde és a pénzügyi piacok instabilitására, valamint a befektetői pszichológia és a piaci magatartás közötti összefüggésekre vezethető vissza (Duarte et al., 2017).

A prediktív modellek kialakítása során egyre nagyobb hangsúlyt kapnak tehát a gépi tanulás eszközei, amelyek segítséget nyújtanak a befektetőknek, a kereskedőknek és a vállalati kockázatkezelésben az optimális döntések meghozatalához. Ezen módszerek elsődleges célja, hogy megtanulják és utána automatikusan felismerjék a különböző mintákat a nagy mennyiségű

adathalmazokban. A legfejlettebb mély tanulási algoritmusok folyamatosan fejlődnek, és ezáltal egyre hatékonyabban képesek az árfolyam-ingadozások előrejelzésére a különféle stratégiák optimalizálása érdekében.

A kockázatkezelés fontossága különösen felértékelődik a magas volatilitású időszakban, mint pl. a 2008-as világválság, a Covid19 vagy az orosz–ukrán háború miatti tőzsdei összeomlás. Az inflációs környezet kiszámíthatatlanság további igényt támaszt a minél hatékonyabb eszközök használatára. Napjainkban a legmodernebb kockázatkezelési technikák túlmutatnak az hagyományos diverzifikáción és egyre inkább előtérbe kerülnek a mesterséges intelligencia alapú megoldások, amelyek a hétköznapijaink szerves részévé válnak. A kereskedési stratégiák esetében az árfolyamelőrejelző modellek kulcsfontosságú árfolyamszinteket képesek meghatározni, amelyek felhasználhatók a fundamentális és a technikai elemzés során, illetve a kockázatkezelés és portfóliómenedzsment területén egyaránt. A kutatásom legfőbb célja a gépi tanulási modellekkel történő prediktív modellezés sajátosságainak feltérképezése. A részletes célkitűzéseket és hipotéziseket a továbbiakban ismertetem.

C1: A kutatásom első célkitűzése annak meghatározása, hogy a különböző neurális mély tanulási modellek milyen mértékben általánosíthatóak, azaz képesek-e különböző válsághelyzetekben is kimagasló prediktív teljesítmény elérésére.

Ebből kifolyólag három különböző időszakot elemzek, amelyben a 2018-as év jelenti a nyugalmi, míg a Covid19 (2020) és az orosz-ukrán konfliktusa kirobbanása (2022) a válsággal sújtott periódust.

K1: Milyen kapcsolat mutatható ki a pénzügyi eszközök volatilitása és az árfolyamelőrejelzési modellek prediktív teljesítménye között?

K2: Milyen előrejelzési torzulásokat okoznak a válságidőszakokban megfigyelhető szélsőséges árfolyammozgások és hogyan reagálnak erre különböző típusú algoritmusok?

K3: Milyen szerepet játszik a hibrid modellek architektúrája a prediktív teljesítmény változásában volatilis piaci környezetben?

A modellezés során kitérek arra is, hogy a vizsgált termékkategóriák közül melyik az, ami a legstabilabb és melyik az, amely a legnagyobb kihívást jelenti a prediktív algoritmusok számára. Jelentős eltérések tapasztalhatók a termékspecifikumok között ugyanis az elemzésben helyet kapnak a tradicionális és nagy múltra visszatekintő részvénytőkepiacok, valamint a gazdasági mércével szinte még gyerekcipőben járó, de annál volatilisabb kriptovaluták. Árupiaci termékek is szerepet kapnak a vizsgálatban, amelyek árfolyamának alakulását rengeteg külső hatás befolyásolja, illetve a devizapiacokról sem szabad megfeledkezni, amely szintén különleges tulajdonságokkal rendelkezik, hiszen az árfolyamokat számos, egymással összefüggő tényező határozza meg, mint például a kamatkülönbségek, az infláció, a politikai stabilitás és a kereskedelmi kapcsolatok. A devizapárok közötti korrelációk is jelentős hatással lehetnek az előrejelzések pontosságára. A részvényindexek hosszabb távon követhetőbb trendeket mutatnak, míg a kriptovaluták és egyes árucikkek árfolyamai sokkal érzékenyebbek lehetnek a rövid távú eseményekre, például a gazdasági ciklusokra vagy szélsőséges történésekre. Ez a volatilitás jelentős kihívást jelent a prediktív modellek számára, hiszen nehezebb pontos előrejelzéseket készíteni olyan piacokon, ahol az árfolyamok gyorsan és nagy mértékben változhatnak. A világgazdaságot érő stresszhatások jelentősen befolyásolják a különböző pénzügyi piacok alakulását, ezért kiemelten fontos, hogy az ilyen időszakokban minél pontosabban meg lehessen becsülni a vizsgált termékek árfolyamait. A gépi tanulási modellek alkalmazásának előnyei közül ki kell

emelni, hogy a többi módszerhez képest pontosabban képesek a nagy mennyiségű múltbéli adatokból felismerni a mintázatokat és azok alapján a jövőben várható árfolyamokat, trendeket előre jelezni. A mély tanulási modellek sajátossága, hogy minél nagyobb mennyiségű adat áll rendelkezésükre, annál hatékonyabban képesek tanulni. Különösen nagy jelentősége van tehát annak, hogy milyen egyedi tulajdonságokkal bíró gazdasági periódusokból származó adatkészleten tanítjuk őket. Az alábbi kutatási kérdésekre keresem a választ:

C2: A dolgozatom második célkitűzése annak a vizsgálata, hogy a gépi tanulási modellek milyen mértékben képesek javítani a pénzügyi eszközök kereskedési teljesítményét a hagyományos buy-and-hold stratégiához képest. Az alábbi kutatási kérdésekre keresem a választ:

K4: Mennyiben képesek a gépi tanulási előrejelzéseken alapuló kereskedési stratégiák kihasználni a piaci anomáliákat, a hatékony piacok elméletével szemben?

K5: Milyen hatása van a különböző termékosztályok (pl. részvények, kriptovaluták, árupiac, devizapárok) volatilitásának a gépi tanulás által támogatott kereskedési stratégiák teljesítményére?

K6: Milyen eltérések tapasztalhatók a gépi tanuláson alapuló stratégiák teljesítményében különböző gazdasági ciklusok alatt?

Az előrejelzéseket felhasználva szabályalapú kereskedési stratégiákat alakítok ki. Ezen stratégiák teljesítményét visszatesztelem és összevetem a passzív befektetési megközelítés eredményeivel, különös tekintettel a hozamra és kockázati mutatókra (kumulatív hozam, Sharpe-mutató, stb.). A cél nem csupán a predikció pontosságának értékelése, hanem annak feltárása is, hogy a modellek által generált döntések ténylegesen eredményeznek-e javulást a kereskedési teljesítményben. Ezen keresztül választ keresek arra, hogy a gépi

tanulási alapú döntéstámogatás mennyiben képes kezelni különböző piaci körülményeket (trend, volatilitás, sokkok). A dolgozat gyakorlati értéke, hogy a vizsgált megközelítés potenciális alternatívát kínál a klasszikus passzív befektetéssel szemben. Mindez különösen releváns a hatékony piacok elméletének (EMH) kontextusában, amely szerint a piaci árfolyamok minden elérhető információt tükröznek, és ezáltal lehetetlenné válik hosszú távon extra hozamot elérni bármilyen prediktív módszerrel. A dolgozatban bemutatott stratégiák, ha képesek szisztematikusan meghaladni a buy-and-hold referenciahozamot, akkor implicit módon megkérdőjelezhetik az EMH gyakorlatias érvényességét. Ezen túlmenően a stratégiák értékelésében a Sharpe-mutató maximalizálása központi szerepet kap, mivel ez a mutató a hozam és a hozam volatilitásának arányát méri, és így alkalmas a kockázattal súlyozott teljesítmény objektív összevetésére. A modellek célja tehát nem pusztán a magas hozam elérése, hanem a stabil, volatilitás-arányos profitabilitás biztosítása. Ennek vizsgálata segíthet megérteni, hogy a gépi tanulás alapú kereskedési rendszerek mennyiben tudnak értéket teremteni olyan környezetben, ahol az információ hatékonyság elvileg kizárja az arbitrázslehetőségeket.

3. ANYAG ÉS MÓDSZER

3.1. Adatok

A kutatásomban részvényindexek (S&P500, DAX, Nikkei225), áruipiaci termékek (nyersolaj-Crude, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) napi árfolyamadatait használtam fel a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. A nyersolaj, arany és ezüst esetében határidős, míg a többi termék esetében azonnali árfolyamokkal dolgoztam. Részben azért erre a periódusra esett a választás, mert itt megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és a háborús krízis (2022) egyaránt, részben pedig azért, mert a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel. Az összehasonlíthatóság szempontjából tehát ez tűnt a legoptimálisabb döntésnek. Az adatokat a www.finance.yahoo.com weboldalról gyűjtöttem össze, kivételt képeznek a kriptovaluták, mert ezek adatai a www.coinmarketcap.com oldalról származnak.

Az adattisztítás és az adatsorok átvizsgálása során a hiányzó adatok kezelésének problémájával is foglalkoznom kellett, melynek jelentősége elsősorban a korrelációs mátrix számításánál jelentkezett, ugyanis az egyes termékek eltérő megfigyelésszámot mutattak. Ezen probléma megoldására a lineáris interpolációs módszert választottam. Az előrejelző módszerek esetében a hiányzó adatoknak nem volt jelentősége, mivel minden termékre külön-külön történt a vizsgálat. A trend és szezonális hatások kiszűrését a későbbiekben tárgyalom a volatilitás meghatározásánál. A predikciók elvégzése során a trendet és szezonalitást külön nem kezeltem, hanem ezt a modellek mintázatfelismerő képességére bíztam. Ezután az adatbázisokat három részegységre bontottam. Az első vizsgált időszak egy nyugalmas

gazdasági környezetre fókuszált 2016. január 1-től 2018. június 30-ig. A második a 2018. január 1. és 2020. június 30. közötti időszakot öleli fel, amely a Covid19 miatt került kiválasztásra. Míg a harmadik szintén egy gazdasági krízissel, az orosz-ukrán konfliktussal kapcsolatos, amely a 2020. január 1. és 2022. június 30. közti időintervallumot jelenti. Az elemzés során a két válságos időszak fontos tényezőként funkcionált a modellek robusztusság-vizsgálata szempontjából. Az empirikus elemzéshez felhasznált adatok leíró statisztikáit a 1-3. táblázat tartalmazza.

1. táblázat: A vizsgált termékek 2016. január 1. és 2018. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	2360,37	2365,41	258,18	1829,08	2872,87
DAX	632	11575,03	12002,46	1243,42	8752,87	13559,60
Nikkei225	613	19315,52	19383,84	2355,25	14952,02	24124,15
Nyersolaj	626	50,81	49,56	9,54	26,21	74,15
Arany	625	1266,21	1271,50	57,64	1073,90	1364,90
Ezüst	625	16,98	16,87	1,25	13,74	20,67
Bitcoin	912	3649,33	1187,47	4189,45	364,33	19497,40
Ethereum	911	233,20	44,89	298,89	0,92	1398,99
Litecoin	912	52,79	6,93	72,31	3,00	358,34
EUR/USD	649	1,14	1,13	0,05	1,04	1,25
GBP/USD	649	1,33	1,32	0,07	1,20	1,48
AUD/USD	649	0,76	0,76	0,02	0,69	0,81

Forrás: saját szerkesztés

Az első vizsgált időszakban (1. táblázat) a részvénytőzsdéken mérsékelt növekedés és viszonylag stabil volatilitás volt tapasztalható. Az S&P 500 index átlaga 2360,37 pont volt, 258,18 pontos szórással, míg a DAX és a Nikkei225 esetében magasabb átlagértékek és szórások jellemezték az időszakot, utalva az európai és ázsiai piacok nagyobb árfolyamingadozásaira. A nyersolaj átlagos ára 50,81 USD volt, azonban viszonylag magas szórással (9,54 USD), ami a nyersanyagpiac érzékenységét tükrözi a geopolitikai és

kereslet-kínálati változásokra. Az arany és ezüst stabilabb értékőrző eszközként viselkedtek, viszonylag alacsony szórással, különösen az ezüst esetében (1,25 USD). A kriptovaluták, különösen a Bitcoin és az Ethereum jelentős volatilitást mutattak ebben az időszakban: a Bitcoin szórása 4189,45 USD, míg az Ethereumé 298,89 USD volt. Ez a magas szórás a digitális eszközök piaci árának gyors felfutását és spekulatív jellegét mutatja. A devizapiacokon az EUR/USD, GBP/USD és AUD/USD árfolyamok viszonylagos stabilitást mutattak, alacsony szórással és szűk intervallumban mozgó minimum-maximum értékekkel. Összességében ez az időszak a hagyományos pénzügyi eszközök számára stabil, a kriptoeszközök számára pedig erőteljes növekedési és volatilitási szakasz volt.

2. táblázat: A vizsgált termékek 2018. január 1. és 2020. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	2862,46	2843,11	195,87	2237,40	3386,15
DAX	627	12099,54	12253,15	911,70	8441,71	13789,00
Nikkei225	606	21865,58	21874,23	1291,52	16552,83	24270,62
Nyersolaj	628	56,18	58,30	13,28	-37,63	76,41
Arany	627	1394,23	1328,10	159,39	1176,20	1793,00
Ezüst	627	16,06	16,14	1,29	11,73	19,39
Bitcoin	912	7679,92	7679,97	2384,93	3236,76	17527,00
Ethereum	911	302,16	207,80	238,30	81,72	1398,99
Litecoin	912	80,24	61,06	48,48	23,46	296,45
EUR/USD	651	1,14	1,13	0,04	1,07	1,25
GBP/USD	651	1,30	1,29	0,05	1,15	1,43
AUD/USD	651	0,71	0,71	0,04	0,57	0,81

Forrás: saját szerkesztés

A második időszakban (2. táblázat), amely részben átfedi a Covid19 járvány kezdetét, a pénzügyi piacokon növekvő volatilitás és strukturális átrendeződés volt megfigyelhető. A részvényindexek különösen az S&P 500 (átlag: 2862,46) és a DAX (átlag: 12099,54) mérsékelt növekedést mutattak az előző

időszakhoz képest, azonban az árfolyamok szórása enyhén csökkent, ami a piac részleges stabilizálódását jelezheti a járvány kitörése előtt. A nyersolaj piacán rendkívüli árzuhanás történt, amit jól jelez a negatív minimum érték (-37,63 USD), amely 2020 áprilisában következett be a határidős piacon. A nemesfémek, különösen az arany, felértékelődtek mint menekülőeszközök: az arany átlaga 1394,23 USD-ra emelkedett, szórása pedig jelentősen nőtt (159,39 USD). A kriptovaluták, például a Bitcoin és az Ethereum, továbbra is magas szórással bírtak, de medián értékeik emelkedése mérsékeltebb, mint korábban, ami a piac érettségének bizonyos jeleit mutatja. A Litecoin esetében szintén emelkedett az átlagár, viszonylag magas szórással. A devizák közül az EUR/USD és GBP/USD párok enyhe értékcsökkenést mutattak, míg az AUD/USD jelentősebb mértékben gyengült, ami az ausztrál gazdaság nyersanyagkitettségre vezethető vissza. Ez az időszak tehát fokozódó bizonytalanságot, de egyben alkalmazkodást is tükröz a hagyományos és új típusú pénzügyi eszközök piacán.

3. táblázat: A vizsgált termékek 2020. január 1. és 2022. június 30. közötti időszakra vonatkozó leíró statisztikái

	Darabszám	Átlag	Medián	Szórás	Min	Max
S&P500	628	3851,17	3915,98	599,47	2237,40	4796,56
DAX	635	13907,57	13950,04	1633,03	8441,71	16271,75
Nikkei225	606	26031,83	27007,45	3214,96	16552,83	30670,10
Nyersolaj	628	63,11	62,57	25,23	-37,63	123,70
Arany	628	1803,00	1809,30	104,27	1477,30	2051,50
Ezüst	628	22,99	23,97	3,70	11,73	29,40
Bitcoin	911	30776,76	33798,01	18183,70	4970,79	67566,83
Ethereum	911	1745,93	1790,25	1384,34	109,21	4800,00
Litecoin	911	116,99	109,43	68,26	30,93	386,45
EUR/USD	651	1,15	1,16	0,05	1,04	1,23
GBP/USD	651	1,32	1,33	0,06	1,15	1,42
AUD/USD	651	0,72	0,72	0,04	0,57	0,80

Forrás: saját szerkesztés

A harmadik időszak (3. táblázat) erőteljes piaci változásokat hozott a Covid19 pandémia és az abból való kilábalás, majd az orosz–ukrán háború következtében kialakult geopolitikai bizonytalanság hatására. Az S&P 500 index átlaga 3851,17 pontra emelkedett, szórása viszont jelentősen, 599,47 pontra nőtt, utalva a növekvő piaci volatilitásra. A DAX és a Nikkei225 indexek szintén növekvő átlag- és maximum értékekkel bírtak, miközben volatilitásuk is emelkedett, különösen a Nikkei225 esetében. A nyersolaj piaca rendkívüli érzékenységgel reagált az orosz–ukrán konfliktusra: az árfolyam szórása 25,23 USD-ra nőtt, a maximum érték pedig elérte a 123,70 USD-t. Az orosz nyersanyagexport, különösen az energiahordozók kiesése vagy bizonytalansága kulcsszerepet játszott az árfolyam-ingadozásokban. A nemesfémek, főként az arany iránti kereslet megnőtt, mint menekülőeszköz iránt, bár az árfolyam magas szinten stabilizálódott, 1803,00 USD átlagárral. A Bitcoin és Ethereum ebben az időszakban értékük csúcsára értek: a Bitcoin átlagosan 30776,76 USD-t ért el, szórása kiugróan magas, 18183,70 USD volt. Ez részben a kockázatkerülés és a spekulatív tőkebeáramlás következménye is lehetett a hagyományos piacok ingadozása mellett. Az az EUR/USD és GBP/USD árfolyamai viszonylag stabilak maradtak, azonban az európai gazdaság közvetlen érintettsége miatt enyhe gyengülés volt megfigyelhető. Összességében ez az időszak a fokozódó geopolitikai feszültségek, az energiapiaci sokkok és a befektetői kockázatkerülés dominanciájának időszaka volt.

A vizsgálatok során egy- és többváltozós módszerekkel is végeztem kísérleteket. Az egyváltozósok esetében a napi záróárfolyamok képezték a predikció alapját, mégpedig úgy, hogy az aktuális időpontbeli árfolyamot a megelőző 50 időegység (szekvencia) adatainak alapján becsülték meg a modellek. A többváltozós vizsgálatok esetében is hasonlóan jártam el, annyi volt a különbség, hogy a napi záró árakon túl, a nyitó, legmagasabb és

legalacsonyabb árfolyamértékek is szerepet kaptak szintén 50 napos szekvenciatarományokkal.

3.2. Alkalmazott módszerek

Simple Recurrent Neural Network (RNN)

Az RNN a mesterséges neurális hálózatok egyik típusa, amely három fő részből áll: bemeneti, rejtett és kimeneti rétegekből. A hagyományos hálózatokhoz képest két fő különbség van. Az egyik, hogy az RNN azonos rejtett rétegben lévő csomópontjai kapcsolatban állnak egymással, a másik, hogy a rejtett réteg bemenetei a jelen időpontban tartalmazzák a bemeneti réteg jelenlegi időpontban létező kimeneteit, valamint a rejtett réteg előző időpontban eltárolt kimeneteit is. Ez a speciális struktúra lehetővé teszi a dinamikus időbeli viselkedés jobb leírását egy idősor szekvencia esetén. Így tehát egy RNN felhasználhatja a korábban megtanult információkat az éppen aktuális minta felismeréséhez, ezáltal hatékonyabb modellezést tesz lehetővé (Bai et al. 2021).

Gated Recurrent Unit (GRU)

A GRU a rekurrens neurális hálózatok (RNN) egyik típusa, amely kiemelkedő teljesítményre képes az idősorok előrejelzésében. Hasonló az általunk tárgyalt másik neurális hálós modellhez (LSTM), viszont a GRU alacsonyabb számítási kapacitásszükséglettel rendelkezik, amely nagymértékben javíthatja a tanulási hatékonyságot. Bemeneti és kimeneti struktúrája megegyezik egy egyszerű RNN-ével. A GRU egység belső szerkezete csak két kaput tartalmaz: az z_t frissítési és az r_t reset kaput. A z_t frissítési kapu határozza meg az aktuális időponthoz mentett előző memória értékét, az r_t visszaállítási kapu pedig meghatározza, hogy az új bemeneti információt hogyan kell kombinálni az előző memória értékével. Az LSTM algoritmussal ellentétben a z_t frissítési kapu egyszerre képes elfelejteni és kiválasztani a memória tartalmát, ami

javítja a számítási teljesítményt és csökkenti a futási idő szükségletet (Xiao et al. 2022).

Long-Short Term Memory (LSTM)

Az LSTM a rekurrens neurális hálózatok (RNN) egyik típusa, amelyet a szekvenciális adatokkal kapcsolatos kutatásokban gyakran alkalmaznak. A hosszú távú memória a tanulási súlyokra, a rövid távú memória pedig a sejtek belső állapotaira utal. Az LSTM az RNN-ek eltűnő gradiens problémájára jött létre, amelynek fő változása az RNN középső rétegének helyettesítése egy blokkal (LSTM blokk). Az LSTM fő jellemzője a hosszú távú affiláció-tanulás lehetősége, ami az RNN-ek esetében lehetetlen volt. A következő időponthoz kapcsolódó adatok előrejelzéséhez a hálózat súlyértékeinek frissítésére van szükség, ami a kezdeti időintervallum adatainak karbantartását igényli. Egy RNN csak korlátozott számú rövid távú affilációt tudott megtanulni; azonban a hosszú távú idősorokat az RNN-ek nem tudják megtanulni. Az LSTM azonban megfelelően tudja kezelni ezeket. Az LSTM modell struktúrája rekurrens alhálózatok halmazát tartalmazza, amit memóriablokkoknak nevezünk. Minden egyes blokk tartalmaz egy vagy több autoregresszív memóriacellát és három többszörös egységet (bemenet, kimenet és felejtés), amelyek a folyamatos írás, olvasás és a sejtek működésének szabályozását végzik (Ortu et al. 2022).

LSTM-GRU hibrid

Az LSTM-en és GRU-n alapuló hibrid LSTM/GRU modell megtartja mindkét modell előnyeit, csökkenti a túlillesztést, és így lehetővé teszi a nagy pontosságú előrejelzések elérését (Zhao et al. 2023). Ebben a modellben az első rejtett réteg az LSTM. Minden egyes LSTM neuron összegyűjti az adatokat, és egy súlyozott értéket generál. Ezután az adatok az LSTM-ből a GRU rétegbe kerülnek, amely a második rejtett réteg. Az LSTM rétegtől a

GRU-rétegit tartó úton ismét súlyozott értéket generálnak. Hasonlóképpen, az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. A GRU rétegtől a sűrű rétegit szintén súlyozott értéket generálunk. A sűrű réteg egy normál neurális hálózati réteg, amely a kimenet előállítására szolgál. A sűrű rétegből az adatok ezután a kimeneti neuronhoz kerülnek (Islam és Hossain 2021).

RNN-LSTM hibrid

Az RNN és az LSTM erősségeinek kihasználása és gyengeségeik kiküszöbölése érdekében az RNN-LSTM hibrid modell alkalmazása jelentősen javítja az idősorok előrejelezhetőségét (Faru et al. 2023). Ennél az algoritmusnál az első rejtett réteg az RNN, melyben a neuronok összegyűjtik az információkat és egy súlyozott érték generálódik. Majd ezután az információ átkerül az RNN rétegből a második rejtett rétegbe az LSTM-be. Az RNN rétegtől az LSTM-ig tartó úton ismét súlyozott értékek generálódnak. Az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. Az LSTM rétegtől a sűrű rétegit szintén súlyozott értékek generálódnak.

RNN-GRU hibrid

Bár a szakirodalomban meglehetősen sokféle hibrid algoritmus felfedezhető, ennek ellenére az RNN-GRU kombinációra kevés kutatás épít. Ez a modell nagyon hasonlít az előzőhöz, tehát az első rejtett réteg az RNN, melyben a neuronok összegyűjtik az információkat és egy súlyozott érték generálódik. Majd ezután az információ átkerül az RNN rétegből a második rejtett rétegbe az GRU-ba. Az RNN rétegtől az GRU-ig tartó úton ismét súlyozott értékek generálódnak. Az adatok ezután a harmadik rejtett rétegbe (sűrű réteg) kerülnek. A GRU rétegtől a sűrű rétegit szintén súlyozott értékek generálódnak.

A modellezéshez a Python programozási nyelv 3.9-es verzióját használtam. A gépi tanulási módszerekhez fejlesztett Scikit-Learn és a Tensorflow könyvtárak egyaránt segítségemre voltak a modellalkotási folyamatban.

3.3. Az alkalmazott szoftverek

A modellfejlesztésekhez a Python programozási nyelv (3.9-es verzió) került alkalmazásra, amelynek használatát több szempont is indokolja. Egyrészt, a Python széleskörű és gyorsan fejlődő ökoszisztémával rendelkezik, különösen az adatelemzés (pl. Pandas, Numpy) és a gépi tanulás (pl. TensorFlow, Keras, Scikit-learn, Pytorch) területén, ami lehetővé teszi a korszerű neurális hálózati modellek hatékony implementálását. Másrészt, a Python nyílt forráskódú és platformfüggetlen, így a fejlesztés és a reprodukálhatóság is költséghatékonyan biztosítható. További előny, hogy a programozási nyelv egyszerű, jól olvasható szintaxisa gyors prototípus-fejlesztést tesz lehetővé, ami különösen hasznos kutatási projektek esetén, ahol a modellek folyamatos finomhangolása szükséges. A Python mellett szólt a keretrendszerek széles választéka, a mélytanulás támogatása és az ipari alkalmazhatóság. A script-eket a Google Colab felületén, valamint lokálisan a Visual Studio Code kódszerkesztő segítségével futtattam.

3.4. A modellek értékelése

Az előrejelzésre használt modellek kiértékeléséhez és pontosságuk megállapításához a szakirodalomban a leggyakrabban a következő mérőszámokat szokták alkalmazni: az átlagos négyzetes hiba négyzetgyöke (RMSE), az átlagos abszolút hiba (MAE), az átlagos abszolút százalékos hiba (MAPE). A disszertációban a MAPE mutatót használtam az eltérések mérésére. Ez a mutató az előrejelzések hibáinak átlagos nagyságát méri, és százalékos formában mutatja meg az eltéréseket.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Minél alacsonyabb a fenti mérőszámok értéke, annál megbízhatóbbak és pontosabbak lesznek az előrejelzések. A MAPE százalékos formában értelmezendő (az eltérések az eredeti értékhez viszonyított arány százalékban kifejezve). Emiatt a MAPE különböző instrumentumok összehasonlításánál is használható, mert nem függ az árfolyam nominális nagyságától. Mivel tanulmányunkban a világ számos pontjáról származó indexeket, valamint két különböző negatív gazdasági esemény hatásait vizsgáltuk, ezért az összehasonlíthatóság miatt a MAPE-mutatót használtuk fel a modellek átfogó értékelésénél.

3.5. Volatilitás vizsgálata

Az eltérő termékek és időszakok szórás adatai nem megfelelőek a volatilitás és a MAPE értékek összehasonlítására, ezért szükséges volt a relatív volatilitást mérő mutató alkalmazására, amelynek kiszámítását az alábbiakban részletezem. Elsőként olyan módszert kellett találni, amely az idősorokban azonosítja a trendeket és el is tudja azokat távolítani, mivel ezek torzíthatják az eredményeket. Ehhez a Seasonal-Trend decomposition using Loess-t (STL) megközelítést használtam. A módszertan részletes leírását a továbbiakban tárgyalom.

3.5.1. STL (Seasonal-Trend decomposition using Loess)

Az STL egy rugalmas idősorelemzési módszer, amely a vizsgált sorozatot három komponensre bontja: a hosszú távú trendre, a szezonális mintázatra és a véletlenszerű reziduumra. Az STL különlegessége a LOESS (Locally Weighted Scatterplot Smoothing) használata, amely képes a nemlineáris, időben változó szezonális mintázatok modellezésére is. Előnye továbbá a

roboztusítása és rugalmassága, így jól alkalmazható például pénzügyi idősorok elemzésénél. Az idősor dekompozíciója az alábbi formában történik:

$$Y_t = T_t + S_t + R_t$$

ahol Y_t az eredeti idősor, T_t a trend, S_t a szezonális komponens, R_t pedig a reziduum. Az STL hatékonyan alkalmazható pénzügyi idősorokon, ahol a szezonális mintázatok idővel változhatnak (Cleveland et al., 1990). A reziduum R_t tartalmazza a rövid távú, trendtől független fluktuációkat, ezért e komponens alkalmas volatilitásvizsgálatra (He et al., 2021).

3.5.2. Relatív volatilitás: variációs koefficiens (CV)

A trendmentesített sorok volatilitását a variációs koefficiens (CV) segítségével mértem. A CV egy dimenzió nélküli mutató, amely lehetővé teszi különböző mértékegységű és nagyságrendű eszközök szórásának összehasonlítását. A képlete a következő:

$$CV = \frac{\sigma(R_t)}{\mu(Y_t)}$$

ahol $\sigma(R_t)$ a reziduális komponens szórása, míg $\mu(Y_t)$ az eredeti idősor átlaga. A mutató érzékeny a sor átlagának nagyságára, így alacsony nominális értékű eszközöknél a CV nagyobb volatilitást mutathat. A CV egyensúlyt teremt az abszolút és relatív szórásalapú volatilitásmérés között és jól alkalmazható klaszteranalízis alapjaként (Brockwell és Davis, 2002).

A relatív volatilitás, tehát az említett módszer (STL) reziduális komponenseiből kerül kiszámításra. Az STL esetében trend és szezonálismentes reziduumokat kapunk.

3.6. Predikció alapú, dinamikusan optimalizált kereskedési stratégia

Az általam alkalmazott algoritmus egy gépi tanulási előrejelzésen alapuló, paraméter-érzékeny kereskedési stratégia implementálása, amely a klasszikus buy-and-hold megközelítéssel kerül összehasonlításra. A stratégia központi eleme, hogy a predikciós és valós árfolyamértékek közötti reláció alapján generál kereskedési pozíciókat, majd különböző stop-loss (SL), take-profit (TP) és volatilitás-becslési ablak (VOL_LOOKBACK) értékekkel optimalizálja a hozam/kockázat arányt. A célja tehát, hogy a kereskedési teljesítményt a Sharpe-mutató szerint maximalizálja. A forrásprogram bemenetét egy többlapos Excel fájl adja, amely instrumentumonként tartalmaz: időbélyeget („Dátum”), valós piaci értékeket (záróárak), becsült értékeket, amelyeket a predikciós modellek generálnak. A stratégia abból indul ki, hogy ha a becsült érték egy adott időpillanatban magasabb, mint a tényleges érték, akkor az árfolyam várhatóan növekedni fog, tehát long pozíciót érdemes felvenni. Ellenkező esetben short pozíció indokolt. Ez formálisan a következőképpen írható le: ha $\hat{P}_t > P_{t-1}$, akkor long pozíciót nyit, amennyibe $\hat{P}_t < P_{t-1}$

A log hozam kiszámítása a következőképpen történik: $r_t = \ln\left(\frac{P_t}{P_{t-1}}\right)$

A stratégiát tovább finomítja egy volatilitásalapú kockázatkezelés, amelyhez három paraméter kerül beállításra:

- SL_MULTIPLIER: stop-loss küszöb aránya az előző időszak volatilitásához képest.
- TP_MULTIPLIER: take-profit küszöb aránya.
- VOL_LOOKBACK: az a periódushossz, amely alapján a volatilitást számítjuk (meghatározott nappal számolt mozgó szórás).

A volatilitás és határértékek így kerülnek számításra:

$$\sigma_t = std_{rolling}(r_t, VOL_LOOKBACK)$$

$$SL_t = SL_MULTIPLIER * \sigma_t$$

$$TP_t = TP_MULTIPLIER * \sigma_t$$

A realizált hozam ezek alapján lesz módosítva, ha a nyereség vagy veszteség eléri a meghatározott szinteket. Például, ha long pozícióban a hozam meghaladja a TP-t, akkor a hozamot levágjuk TP értéken; ha veszteség SL alá esik, akkor levágjuk -SL értéken. Ugyanez fordítva short pozícióra.

Erre az alap stratégiára építve két másik módszert is beépítettem és teszteltem is. Az egyik esetében 5 napos gördülő MAPE mutatót számol és csak akkor nyit pozíciót az algoritmus, ha meghatározott küszöbérték alatt van az eltérés mutató. Jelen esetben 3%-ot állapítottam meg, tehát egyfajta szűrőként működik itt a MAPE a pozíciónyitáshoz. A másik alternatív is a gördülő MAPE mutató értékét használja csak a dinamikus pozícióméret meghatározásához. Mégpedig úgy, hogy nagyobb MAPE esetén kisebb pozícióméretet vesz fel, míg ellenkező esetben nagyobb méretű allokációt valósít meg.

A program statikus és kumulatív teljesítményelemzést végez, amely minden egyes paraméterkombináció és vizsgált instrumentum esetén kiszámítja a legfontosabb statisztikai mutatókat. Ezek közé tartozik az átlagos napi hozam (μ), a napi hozam szórása (σ), valamint a Sharpe-mutató, amelyet a szokásos évesített képlet alapján számítunk: $\frac{\mu}{\sigma} * \sqrt{252}$. Ezen túlmenően a függvény kiszámítja a kumulált hozamot, a maximális visszaesést (drawdown), amely a kumulált hozamgörbe lokális maximumai és mélypontjai közötti legnagyobb különbséget jelenti, valamint a nyertes ügyletek arányát (winrate). A számításokat a buy-and-hold benchmark stratégiára és a dinamikusan kezelt stratégiára külön-külön végzi el, lehetővé téve a két megközelítés többdimenziós összehasonlítását. Az optimalizációs eljárás során az

algoritmus egy előre meghatározott paraméterrácson keresztül iterál. Ez a rács a következő értékeket tartalmazza: $SL \in \{0.5, 1.0, 1.5\}$, $TP \in \{1.5, 2.0, 3.0\}$, és $VOL_LOOKBACK \in \{10, 20, 30\}$. Az összes lehetséges kombinációra – összesen 27 esetben – lefuttatásra kerül a stratégia, majd a rendszer kiválasztja azt a paraméterkonfigurációt, amelynél a Sharpe-mutató a legmagasabb. Az így meghatározott beállítás az adott instrumentumra optimalizált paraméterkészletként kerül eltárolásra. Az elemzés végén az algoritmus grafikus összehasonlítást végez oszlopdiagram formájában. Ez az ábra minden instrumentum esetén bemutatja a négy stratégia kumulált hozamait. Ennek segítségével jól láthatóvá válik, hogy a modell képes-e konzisztensen felülmúlni a passzív befektetési stratégiát, vagyis van-e gyakorlati értéke a predikciós modellre épített, paraméterhangolt kereskedési megközelítésnek.

Összegzésként elmondható, hogy a program egy általánosan alkalmazható eszköz predikcióalapú befektetési stratégiák elemzésére. Legfőbb jellemzői közé tartozik a prediktív komponens explicit integrálása, a parametrikus kockázatkezelés alkalmazása, valamint az automatikus optimalizáció és a klasszikus buy-and-hold benchmark stratégiával való szisztematikus összehasonlítás. A kód nemcsak szimulációs környezetben használható, hanem backtesting rendszerekhez, gépi tanulási modellek validálásához és érzékenységvizsgálatokhoz is hatékonyan adaptálható.

A kereskedési stratégiák alkalmazása során hasonlóan a legtöbb szakirodalomhoz itt sem vettem figyelembe az adókat, tranzakciós és egyéb költségeket, tehát az eredmények a bruttó kumulált hozamokat reprezentálják.


4. EREDMÉNYEK

4.1. Volatilitás vizsgálatának eredményei

A volatilitás és MAPE összefüggéseinek vizsgálatát az aktivációs függvényoptimalizálási folyamat után végeztem el. A volatilitási értékek alapján egyértelműen kiemelkednek a kriptovaluták, különösen 2018-ban: az Ethereum (0,0475) és a Litecoin (0,0432) extrém magas értékeket mutatnak, szemben például a devizapárookra jellemző alacsony CV értékekkel (EURUSD: 0,0032). 2020-ban a nyersolaj mutat rendkívül magas volatilitást (0,1005), ami a Covid19 időszakához kapcsolható piaci sokkok következménye. A klasszikus részvényindexek, mint az S&P500 vagy a DAX, szintén magasabb volatilitással rendelkeztek 2020-ban, mint 2018-ban vagy 2022-ben, jelezve a piaci bizonytalanság fokozódását.

Az összevont és minden időszakra kiterjedő regressziós elemzés alapján (1. ábra) a relatív volatilitás (CV_STL) és az egyváltozós MAPE között szignifikáns, pozitív kapcsolat figyelhető meg. A regressziós koefficiens értéke 1,2937, ami azt jelenti, hogy a volatilitás egységnyi növekedése átlagosan 1,2937 egységgel növeli az előrejelzési hibát. Az együttható szignifikanciája ($p < 0,01$) megerősíti, hogy a kapcsolat statisztikailag is erős. A konstans értéke 0,0049, de nem szignifikáns, így a modellben a MAPE szintjét alapvetően a volatilitás szintje magyarázza. Az eredmény azt sugallja, hogy az egyváltozós modellek előrejelzési teljesítményét jelentősen befolyásolja a piac ingadozása. Az illeszkedés mértéke (R^2) 76,28%-os, amely meglehetősen magas magyarázóerőt feltételez. Az egyváltozós MAPE értékek tekintetében 2018-ban a legrosszabb predikciós teljesítmény a Litecoin esetében figyelhető meg (0,1095), amit a Bitcoin követ (0,1011). Ugyanebben az évben a legalacsonyabb hibaértékek devizapárokhöz kötődnek, például a GBPUSD (0,0047) és az AUDUSD (0,0055) esetében. 2020-ban a nyersolaj a

MAPE értékek (0,1023) tekintetében is kirívóan viselkedik megerősítve, hogy a piac hektikus mozgásai jelentősen rontják az előrejelzési teljesítményt.




1. ábra: A relatív volatilitás és az egyváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben

Forrás: saját szerkesztés

A többváltozós modellben (2. ábra) a volatilitás hatása még erősebben jelentkezik: a CV_STL regressziós koefficiense 1,6224, amely szintén szignifikáns ($p < 0,01$). Ez arra utal, hogy a többváltozós előrejelzési rendszerek még érzékenyebbek a volatilitásra, vagyis a bemeneti komplexitás nem csökkenti, hanem esetenként növeli a hibaérzékenységet piaci ingadozás esetén. A konstans itt -0,0009, szintén nem szignifikáns, így a modell változékonyságának meghatározó tényezője továbbra is a relatív volatilitás. A magas koefficiens érték megerősíti, hogy még a fejlettebb, többváltozós modellek esetén is kulcsszerepet játszik a volatilitás a predikciós teljesítmény alakításában. Az illeszkedés mértéke (R^2) 90,58%-os, amely az egyváltozóséhoz képest még magasabb magyarázóerőt mutat. A MAPE értékek

esetén a tendencia hasonló, de a hibák jellemzően alacsonyabbak vagy közel azonosak az egyváltozós modellekhez képest. Érdekesség, hogy 2018-ban a Litecoin többváltozós MAPE-je (0,1198) még magasabb is, mint az egyváltozós, ami prediktorválasztási problémákra utalhat. A legtöbb esetben azonban a többváltozós modellek kissé javítanak az előrejelzési pontosságon, például a Nikkei225 esetében 2020-ban (0,0203 vs. 0,0204), illetve a GBPUSD 2022-es értékeinél (0,0040 vs. 0,0063).



2. ábra: A relatív volatilitás és a többváltozós átlagos MAPE értékek kapcsolata időszakok szerinti megjelenítésben

Forrás: saját szerkesztés

A relatív volatilitás és a MAPE értékek kapcsolatát differenciált modellenkénti bontásban 2018-as, 2020-as és 2022-es időszakokra vonatkozóan a 4-6. táblázatok tartalmazzák, STL alapú megközelítésben. Ezeket a következőkben részletesen is bemutatom.

A 4. táblázat a relatív volatilitás (CV_STL) és az egy-, valamint többváltozós előrejelzési hibák (MAPE) közötti kapcsolatot mutatja be a 2018-as időszakra,

hat-hat neurális hálózati modell esetében. Az eredmények alapján minden egyváltozós modell esetében szignifikáns, pozitív kapcsolat áll fenn a volatilitás és a MAPE között, vagyis minél magasabb az adott pénzügyi eszköz volatilitása, annál nagyobb a predikciós hiba. Az egyváltozós vizsgálatoknál a legnagyobb regressziós koefficiens az LSTM modell esetében figyelhető meg (2,920), míg a legalacsonyabb az GRU-nál (1,528), ami a különböző hálózati architektúrák eltérő érzékenységét jelzi a volatilitással szemben. Az R^2 értékek alapján szintén a GRU modell esetén figyelhető meg a legnagyobb magyarázóerő ($R^2 = 0,9713$), míg az RNN-nél a leggyengébb ($R^2 = 0,6134$). Az eredmények megerősítik, hogy a relatív volatilitás erős és stabil prediktora az egyváltozós predikciós teljesítménynek. A táblázat második része a relatív volatilitás és a többváltozós előrejelzési hibák (MAPE) közötti összefüggést mutatja be. Az eredmények azt jelzik, hogy minden modell esetében szignifikáns és pozitív kapcsolat áll fenn a volatilitás és az előrejelzési hiba között, ami arra utal, hogy a volatilisabb eszközöknél nagyobb hibával lehet előrejelezni az árfolyamokat több inputváltozó bevonása esetén is. A legmagasabb regressziós koefficiens a RNN-LSTM-nél figyelhető meg (2,856), míg a legalacsonyabb a LSTM-GRU-nál (1,662), ami azt mutatja, hogy bizonyos architektúrák érzékenyebbek a volatilitás hatásaira. Az R^2 értékek alapján a LSTM-GRU esetén tapasztalható legjobb (0,9651), míg az RNN-LSTM-nél a alacsonyabb (0,7951) regressziós modellilleszkedés. Összességében elmondható, hogy az egy- és többváltozós modellek esetében is stabil, erős kapcsolat figyelhető meg a relatív volatilitás és a predikciós hiba között.

4. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei a nyugalmi időszakra vonatkozóan (2018)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	2,422*** (0,608)	2,920*** (0,578)	1,528*** (0,083)	2,128*** (0,315)	2,304*** (0,168)	1,817*** (0,275)
Konstans	-0,002 (0,013)	-0,006 (0,013)	-0,000 (0,002)	-0,001 (0,007)	-0,003 (0,004)	0,002 (0,006)
Megfigyelések	12	12	12	12	12	12
R ²	0,6134	0,7185	0,9713	0,8207	0,9498	0,8132
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	1,830*** (0,264)	2,854*** (0,346)	1,810*** (0,188)	1,662*** (0,100)	2,856*** (0,458)	1,870*** (0,239)
Konstans	0,000 (0,006)	-0,008 (0,008)	-0,004 (0,004)	-0,001 (0,002)	-0,007 (0,010)	-0,001 (0,005)
Megfigyelések	12	12	12	12	12	12
R ²	0,8273	0,8720	0,9022	0,9651	0,7951	0,8595

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

Az 5. táblázat a 2020-as időszakra vonatkozóan mutatja be a relatív volatilitás (CV_STL) és az egy-, valamint többváltzóós előrejelzési hibák (MAPE) közötti kapcsolatot hat-hat neurális hálózati modell esetében. Az összes egyváltozós modell esetében a volatilitás regressziós együtthatója szignifikáns és pozitív, ami megerősíti, hogy a magasabb volatilitás a predikciós hiba növekedésével jár együtt ebben a válságokkal terhelt időszakban. A legalacsonyabb koefficiens a GRU modellnél (0,845), míg a legmagasabb az RNN modellnél (1,158) figyelhető meg, amely az architektúrák volatilitással szembeni eltérő érzékenységét tükrözi. Az R² értékek mindegyik modellnél rendkívül magasak (mindegyik meghaladja a 90%-ot), ami azt jelzi, hogy a regressziós elemzés magyarázóereje kiemelkedő a vizsgált időszakban. A

táblázat második része a relatív volatilitás (CV_STL) és a többváltozós előrejelzési hibák (MAPE) kapcsolatát hivatott bemutatni. Az eredmények ebben az esetben is minden modellnél statisztikailag szignifikáns és pozitív kapcsolatot jeleznek, vagyis a volatilitás növekedésével együtt nő a többváltozós predikciós hiba is. A legmagasabb regressziós együttható a RNN-LSTM modell esetén figyelhető meg (2,847), míg a legalacsonyabb érték a GRU-nál (0,828), ami a volatilitással szembeni nagyobb robusztusságra utalhat. A determinációs együtthatók (R^2) kiemelkedően magasak minden modellnél (86 és 98% közötti), különösen az LSTM esetében (0,9714), amely a legjobb magyarázóerővel bír. Ezek az eredmények megerősítik, hogy a 2020-as, pandémiával sújtott időszakban is fennállt az erős kapcsolat a piaci ingadozás mértéke és a modellek előrejelzési hibája között, még a fejlettebb, hibrid modellek esetében is.

5. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei a Covid19 időszakra vonatkozóan (2020)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,158*** (0,067)	0,964*** (0,044)	0,845*** (0,077)	0,984*** (0,046)	0,984*** (0,100)	0,936*** (0,064)
Konstans	0,005* (0,002)	0,004** (0,002)	0,006** (0,003)	0,005*** (0,002)	0,011** (0,004)	0,007*** (0,002)
Megfigyelések	12	12	12	12	12	12
R ²	0,9676	0,9795	0,9228	0,9787	0,9067	0,9549
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	2,279*** (0,158)	0,896*** (0,049)	0,828*** (0,066)	0,911*** (0,050)	2,847*** (0,289)	1,150*** (0,146)
Konstans	-0,010* (0,006)	0,004** (0,002)	0,005* (0,002)	0,004** (0,002)	-0,020* (0,010)	0,005 (0,005)
Megfigyelések	12	12	12	12	12	12
R ²	0,9543	0,9714	0,9403	0,9706	0,9065	0,8616

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A 6. táblázat a 2022-es időszakra vonatkozóan mutatja be a relatív volatilitás (CV_STL) és az egy-, valamint többváltozós előrejelzési hibák (MAPE) közötti. Minden egyváltozós modellnél pozitív és szignifikáns kapcsolat figyelhető meg, ami azt jelenti, hogy a volatilitás emelkedése továbbra is az előrejelzési hiba növekedésével jár együtt. A regressziós koefficiensek 1,149 (GRU) és 1,969 (RNN-LSTM) között mozognak, ami viszonylag egységes, közepes érzékenységre utal a volatilitás hatására. A magyarázóerő (R²) minden modell esetében magas, 85 és 92% közötti. A táblázat második része a relatív volatilitás (CV_STL) és a többváltozós előrejelzési hibák (MAPE) közötti kapcsolatot reprezentálja. Itt is minden modell esetében szignifikáns és pozitív regressziós együttható figyelhető meg. A koefficiensek viszonylag

szűk sávban mozognak, a legalacsonyabb érték a GRU modell esetében (1,312), míg a legmagasabb az RNN-LSTM-nél jelentkezik (2,033), ami a különböző architektúrák eltérő volatilitás-érzékenységet mutatja. Az R^2 értékek magasak, 82 és 97% között alakulnak, kiemelkedő magyarázóerőt mutatva, különösen az LSTM-GRU esetében (97,48%). Az eredmények konzisztensen megerősítik a korábbi évek megfigyeléseit: a volatilitás strukturális jelenléte alapvetően befolyásolja a predikciós teljesítményt, még a komplexebb, többváltozós mélytanulási modellek esetében is.

6. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek regressziós eredményei az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,856*** (0,205)	1,403*** (0,132)	1,149*** (0,133)	1,539*** (0,192)	1,969*** (0,254)	1,598*** (0,165)
Konstans	-0,002 (0,004)	-0,000 (0,002)	0,003 (0,002)	0,000 (0,003)	-0,001 (0,005)	-0,001 (0,003)
Megfigyelések	12	12	12	12	12	12
R^2	0,8915	0,9192	0,8819	0,8656	0,8570	0,9032
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	1,370*** (0,153)	1,523*** (0,225)	1,312*** (0,115)	1,395*** (0,071)	2,033*** (0,225)	1,903*** (0,188)
Konstans	0,003 (0,003)	-0,000 (0,004)	-0,001 (0,002)	-0,001 (0,001)	-0,003 (0,004)	-0,003 (0,003)
Megfigyelések	12	12	12	12	12	12
R^2	0,8889	0,8206	0,9283	0,9748	0,8904	0,9112

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A modellek összevont számszerűsíthető vizsgálatához és összehasonlításához készítettem egy panel regressziós elemzést is egy- és többváltozós megközelítésre vonatkozóan, az összes vizsgált időszakra, amelynek eredményeit a 7. táblázat tartalmazza. Az egyváltozós MAPE és a relatív

volatilitás (CV_STL) kapcsolatának feltárása során arra a következtetésre jutottam, hogy az együtthatók kivétel nélkül mind pozitívak és statisztikailag szignifikánsak ($p < 0.01$), ami arra utal, hogy a volatilitás emelkedése a panel regressziós modell esetén is szisztematikusan együtt jár a predikciós hibák növekedésével. A legnagyobb érzékenység az RNN-nél figyelhető meg (1,485), míg a legalacsonyabb a GRU esetében (0,923). Az R^2 értékek eltérő magyarázóerőt mutatnak: a legjobb értéket a GRU modell (0,8632) érte el, míg a legalacsonyabbat az LSTM (0,5259), ami jól tükrözi a modellek heterogén teljesítményét. A többváltozós neurális hálózati modellek esetében szintén mindenhol pozitív és szignifikáns kapcsolat figyelhető meg a relatív volatilitás és MAPE értékek között az összes időszakra aggregált panel regressziók alapján. A legmagasabb regressziós együttható az RNN-LSTM-nél látható (2,719), míg a legalacsonyabb a GRU-nál jelentkezik (1,035), ami ismételten a GRU modellek valamivel robusztusabb viselkedésére utal magasabb volatilitás mellett. Az R^2 értékek modellfüggően 60 és 90% között mozognak, tehát a magyarázóerő változó, de általában erős különösen a RNN modell esetében (90,72%), ami kiemelkedő illeszkedést jelez. Az eredmények alapján elmondható, hogy az egy- és többváltozós mélytanulási modellek esetében is fennáll a volatilitás előrejelzési hibára gyakorolt szisztematikus hatása, amely időszakokon átívelően is konzisztensek maradnak. Ez megerősíti a volatilitás kulcsszerepét a predikciós teljesítmény alakulásában még komplexebb modellstruktúrák mellett is.

7. táblázat: A vizsgált termékek relatív volatilitás mutatóinak és a MAPE értékeinek panel regressziós eredményei az összes időszakra vonatkozóan

	(1) Univ- RNN	(2) Univ- LSTM	(3) Univ- GRU	(4) Univ- LSTM- GRU	(5) Univ- RNN- LSTM	(6) Univ- RNN- GRU
CV_STL	1,485*** (0,201)	1,418*** (0,231)	0,923*** (0,067)	1,274*** (0,135)	1,373*** (0,131)	1,185*** (0,114)
Konstans	0,004 (0,005)	0,003 (0,006)	0,006*** (0,002)	0,005 (0,004)	0,007* (0,003)	0,006** (0,003)
Megfigyelések	36	36	36	36	36	36
R ²	0,6157	0,5259	0,8632	0,7251	0,7645	0,7606
	(7) Multi- RNN	(8) Multi- LSTM	(9) Multi- GRU	(10) Multi- LSTM- GRU	(11) Multi- RNN- LSTM	(12) Multi- RNN- GRU
CV_STL	2,144*** (0,118)	1,369*** (0,192)	1,035*** (0,104)	1,117*** (0,073)	2,719*** (0,188)	1,198*** (0,112)
Konstans	-0,007** (0,003)	0,003 (0,005)	0,003 (0,003)	0,003 (0,002)	-0,012** (0,005)	0,006* (0,004)
Megfigyelések	36	36	36	36	36	36
R ²	0,9072	0,5982	0,7794	0,8734	0,8604	0,8102

Forrás: saját szerkesztés a STATA 17 eredmények alapján

Zárójelben a sztenderd hibák

* $p < 0.1$, ** $p < 0.05$, *** $p < 0.01$

A 7. táblázat összevont panel regressziós eredményei lehetőséget biztosítanak arra, hogy a modellek predikciós érzékenységet összehasonlítsuk a relatív volatilitás (CV_STL) függvényében. A regressziós koefficiensek pozitív értékei minden modell esetében megerősítik, hogy a volatilitás növekedése növeli az előrejelzési hibát (MAPE), ugyanakkor a koefficiensek nagysága alapján következtethetünk arra, mely modellek a legkevésbé érzékenyek a volatilitásra, azaz robusztusabbak. Ezek alapján először az egy- és többváltozós modellek összehasonlítás következik.

Az eredmények alapján világosan látszik, hogy a legtöbb modellpár esetében a többváltozós verzió érzékenyebben reagál a volatilitásra, mivel a CV_STL koefficiense nagyobb. Az RNN, a GRU, az RNN-LSTM, valamint az RNN-GRU esetében az egyváltozós modellek koefficiensei a kedvezőbbek. Az

LSTM-nél és az LSTM-GRU-nál azonban pontosan az ellenkezője figyelhető meg. Összességében a legtöbb esetben a többváltozós modellek nagyobb érzékenységet mutatnak a volatilitással szemben, amit a magasabb regressziós koefficiensek jeleznek. Ez arra utal, hogy bár a többváltozós modellek jellemzően magasabb predikciós teljesítményt nyújtanak (magasabb R^2 értékek is ezt tükrözik, pl. Multi-RNN: 0,9072 szemben Univ-RNN: 0,6157), ugyanakkor sérülékenyebbek lehetnek piaci turbulenciák esetén, azaz a predikciós hiba jobban függ a volatilitás szintjétől. Éppen ezért, alkalmazásuk során a volatilitásfüggőség explicit kezelése különösen indokolt lehet.

Az egyszerű és hibrid modellek összehasonlításával is fontos következtetésekre juthatunk. Az egyváltozós vizsgálatok esetén az RNN és az ebből képzett komplex módszerek eredményei alapján azt a megállapítást tehetjük az, hogy a hibridizált változatok kevésbé érzékenyen reagáltak a volatilitásra, mint az alapmodell. Ugyanez igaz az LSTM-re, valamint ennek hibrid változataira. A GRU-nál azonban pont az ellenkezője tapasztalható. Itt a hagyományos alaptípus kisebb volatilitás érzékenységet mutatott, mint a hibrid modellváltozatok. A többváltozós vizsgálatoknál a GRU alapmodell szintén jobban teljesített a hibridváltozatoknál. Az RNN, valamint az LSTM összehasonlításokat tekintve jóval vegyesebb a kép, mivel ezekben az esetekben előfordult, hogy a hibrid modell kisebb érzékenységet mutatott (RNN-GRU és LSTM-GRU) az alapváltozatnál.

A regressziós koefficiensek alapján megállapítható, hogy az egyváltozós modellek átlagosan kevésbé érzékenyek a volatilitásra, tehát robusztusabb teljesítményt mutatnak. Az egyszerű architektúrák (különösen GRU) alacsonyabb volatilitási érzékenységgel bírnak, mint a hibrid modellek. A hibrid modellek teljesítménye széles skálán mozog: míg egyesek (pl. RNN-LSTM) erősen érzékenyek a volatilitásra, mások (pl. RNN-GRU) meglepően stabilak. A modellválasztás tehát döntően befolyásolja, mennyire képes az


adott architektúra ezt a hatást kezelni. Ez az összehasonlítás rámutat arra, hogy nemcsak a modellek típusát, hanem azok bemeneti struktúráját (egyváltozós vs. többváltozós) is gondosan mérlegelni kell predikciós rendszerek kialakításakor, különösen kimagasló volatilitású piaci környezetben.

4.2. Kereskedési stratégiák eredményeinek összehasonlítása

A kereskedési stratégiák alapját a legjobb előrejelző teljesítményt nyújtó modellek által generált prediktív értékek képezték minden időszak és termékkategória esetén. A továbbiakban a valós és becsült értékek visszatesztelésén alapuló módszerek hozam és kockázati mutatóinak összehasonlítása következik.

A 2018-as év adatai alapján (3. ábra) világosan kirajzolódik, hogy a hagyományos buy-and-hold stratégia számos esetben alulmaradt a fejlettebb, gépi tanulásra épülő modellekkel szemben. Különösen érvényes ez a volatilis eszközosztályokra, például a kriptovalutákra és részben a nemesfémekre, de a részvény- és devizapiacokon is jól érzékelhető volt a prediktív modellek előnye. A részvénypiaci indexeknél (S&P500, DAX) is egyértelműen kirajzolódott a MAPE-modellek fölénye. Az S&P500 esetében például a buy-and-hold csupán 0,83%-os kumulált hozamot ért el, míg a MAPE-alapú stratégiák 12-14% közötti eredményt produkáltak kiemelkedő, 2,65 körüli Sharpe-mutató mellett. A DAX esetében a buy-and-hold negatív hozama (-17,12%) kontrasztban állt a MAPE-modellek pozitív teljesítményével, amelyek nemcsak javuló hozamot, hanem jelentősen kedvezőbb kockázati profilt is mutattak. A Nikkei225 indexnél azonban minden stratégia negatív hozamot generált. Az arany és az ezüst esetében is egyértelmű hozamnövekedés volt tapasztalható. A MAPE-pozíció stratégia például az arany esetében 7,02%-os hozamot és 3,1859-es Sharpe-mutatót produkált, miközben a buy-and-hold alig mutatott pozitív teljesítményt. Egyedüli kivételt

a nyersolaj jelentett: míg a buy-and-hold stratégia 20,56%-os pozitív hozamot ért el, addig az aktív stratégiák nem tudtak érdemben javítani ezen. A prediktív modellek Sharpe-mutatói negatívak voltak, a maximális visszaesések pedig jóval magasabb szintet értek el (pl. MAPE-szűrő: 0,5712), ami arra utal, hogy a modell nem tudta megfelelően lekövetni az olajpiac nemlineáris és turbulens mozgásait. A legmarkánsabb különbségek a kriptovaluták esetében jelentkeztek. A Bitcoin buy-and-hold hozama erősen negatív volt (-73,38%), míg az Alapstratégia több mint 86%-os kumulált hozamot ért el. Hasonlóan jelentős volt a javulás az Ethereum és a Litecoin esetében, ahol a gépi tanulási alapú stratégiák jelentős hozamelőnyt biztosítottak, a Sharpe-mutatók pedig rendre meghaladták a kettőt. A devizapároknál (EURUSD, GBPUSD, AUDUSD) a gépi tanulási modellek Sharpe-mutatói jellemzően pozitívak és magasabbak voltak, mint a buy-and-hold stratégiáé, még akkor is, ha az abszolút hozamszintek mérsékeltek maradtak. Emellett szinte minden esetben alacsonyabb maximális visszaesést (drawdownt) eredményeztek. Általánosságban elmondható, hogy az Alap-, MAPE-szűrő és MAPE-pozíció stratégiák 2018-ban szinte minden eszközosztályban felülmúlták a buy-and-hold megközelítést, különösen hozam és kockázat-hozam arány (Sharpe-mutató) tekintetében. A maximális visszaesés szintén alacsonyabb maradt a prediktív modellek esetében, ami a hatékonyabb kockázatkezelésre utal. A kivételt jelentő olajpiac kiemeli, hogy bár a gépi tanulás ígéretes eszköz a pénzügyi előrejelzésekben, vannak olyan piaci környezetek, ahol a prediktív teljesítmény nem garantált.




3. ábra: A 4 kereskedési stratégia összehasonlítása a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A Covid19 által fémjelzett 2020-as év (4. ábra) extrém piaci környezete élesen megvilágította a különböző befektetési stratégiák közötti teljesítménykülönbségeket. A hagyományos buy-and-hold megközelítés számos eszközosztályban alulmaradt a gépi tanulásra épülő, adaptív stratégiákkal szemben, amelyek nemcsak magasabb hozamot, hanem jobb kockázat/hozam arányt és kisebb maximális visszaesést is biztosítottak. Az S&P500 példája különösen jól szemlélteti a prediktív stratégiák előnyeit. Míg a buy-and-hold hozama enyhén negatív volt (-5,65), az Alapstratégia 74,26%-os kumulált hozamot produkált. A Sharpe-mutató a prediktív modelleknél extrém magas értéket (4,7) vett fel, szemben a buy-and-hold negatív arányával (-0,2465). A DAX és a Nikkei225 esetében is hasonló eredmények születtek: a hagyományos stratégia veszteségei mellett a MAPE-alapú modellek pozitív hozamot és jóval kedvezőbb kockázati mutatókat biztosítottak. A nemesfémek esetében szintén jól teljesítettek az aktív stratégiák. Az aranynál a MAPE-

pozíció stratégia 23%-os hozamot és 2,48-as Sharpe-mutatót ért el, egyértelműen felülteljesítve a buy-and-hold-ot. A maximális visszaesések is mérsékeltebbek voltak az aktív modellek esetében, ami a jobb kockázatkezelést tükrözi. A nyersolajpiac 2020-ban is kivételként viselkedett. Míg a buy-and-hold stratégia 17,12%-os hozamot mutatott, az aktív stratégiák jelentős veszteségeket szenvedtek el (-45,52%) és negatív tartományba eső Sharpe-mutatókat produkáltak. Ez valószínűleg annak tudható be, hogy a piaci extrémítások (negatív határidős árfolyam) olyan strukturális változásokat jelentettek, amelyekre a prediktív algoritmusok nem voltak felkészítve. A modellek a szokványos volatilitási mintázatokat követve téves irányokat preferáltak, ez pedig látványosan rontotta az eredményeket. A kriptovaluták piacain az aktív megközelítések szinte minden esetben jelentős felülteljesítést eredményeztek. A Litecoin buy-and-hold hozama 1,23%, míg a prediktív stratégia 127,96%-os kumulált hozamot és 2,75 fölötti Sharpe-mutatót hozott. A Bitcoin és Ethereum esetében is hasonló volt a tendencia. A gépi tanulási modellekre alapozott stratégiák (Alapstratégia és MAPE-pozíció) hozama meghaladta a 100%-ot és stabilan 2-3 közötti Sharpe-értéket mutattak. A devizapiacokon azonban a prediktív stratégiák előnye, már kisebb mértékben volt érzékelhető. Bár az abszolút hozamkülönbségek nem voltak drámaiak, a gépi tanulási modellek a legtöbb esetben javították a kockázat/hozam arányt és csökkentették a visszaesést. A 2020-as évben, a rendkívüli piaci volatilitás közepette, a gépi tanulási stratégiák nem csupán alternatívát, hanem számos esetben hatékonyabb és stabilabb megoldást nyújtottak a portfóliókezelés során. Az aktív stratégiák kiemelkedő eredményeket értek el a részvénypiacokon, a kriptoeszközök piacán és a nemesfémek területén. A devizapiacokon mérsékeltebb, de stabil javulást hoztak. Ugyanakkor az olajpiac ismételten kihívás elé állította a prediktív rendszereket.




4. ábra: A 4 kereskedési stratégia összehasonlítása a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022-es év piaci környezete (5. ábra) jelentős kihívások elé állította a befektetőket. A geopolitikai feszültségek, az inflációs nyomás és a monetáris szigorítások komoly volatilitást eredményeztek a hagyományos eszközosztályokban. Ebben a bizonytalan környezetben a prediktív, gépi tanulási modellekre épülő stratégiák több esetben is hatékony védelmet nyújtottak a veszteségekkel szemben, sőt, sokszor pozitív hozamot biztosítottak ott, ahol a buy-and-hold jelentős visszaesést szenvedett el. A részvénytőzsiadokon a buy-and-hold megközelítés nem tekinthető hatékonynak ugyanis az S&P500 index -22,42%-os hozamot produkált -1,81-es Sharpe-mutató mellett, míg az Alapstratégia 13,49%-os pozitív eredményt és 1,46-os Sharpe-mutatót ért el. A DAX esetében még erőteljesebb volt a kontraszt. A buy-and-hold -31,16-os hozammal és -2,06-os Sharpe-mutatóval zárt, míg a prediktív stratégiák pozitív teljesítményt mutattak, bár szerényebb mértékben. A Nikkei225 esetében is egyértelmű az aktív stratégiák fölénye. A buy-and-

hold -7,55%-os, míg az Alapstratégia 18,55%-ra hozamszinteket produkált, rendkívül magas (2,16) Sharpe-mutató mellett. Az arany és az ezüst esetében a prediktív stratégiák a hozamot növelték és jobb Sharpe-mutatót értek el, mint a passzív megközelítés. A nyersolaj ismételten kivételként viselkedett. A buy-and-hold stratégia kimagasló, 35,48%-os hozamot realizált, szemben a versenytárs módszerekkel, amelyek közül csak a MAPE-szűrő volt képes pozitív eredményre (10,89%). Ez az eltérés azt jelezheti, hogy a nyersolaj ármozgását olyan nemlineáris, szokatlan dinamikák mozgatták (geopolitikai sokkok, ellátási lánc anomáliák), amelyekre a gépi tanulási algoritmusok nem tudtak megfelelően reagálni. A kriptopiacokat 2022-ben brutális korrekció jellemezte. A Bitcoin (-85,01%), Ethereum (-120,93%) és Litecoin (-101,92) buy-and-hold hozamai súlyos veszteségeket mutattak. Ugyanakkor a prediktív stratégiák jelentős veszteségcsökkentést értek el, amely különösen a Litecoin esetében látványos, mivel az Alapstratégiával 49,07%-os hoztamot sikerült realizálni, 2,17-es Sharpe-mutató mellett. A Bitcoin esetében is nyereséget mutatott az aktív stratégiaépítés, azonban az Ethereumnál nem sikerült kompenzálni a negatív trendet. A devizapiacokon is kedvezőbb eredményeket hoztak a prediktív stratégiák. Az EURUSD buy-and-hold -7,65%-os hozammal zárt, míg az Alapstratégia MAPE-alapú stratégia 7,91%-ot produkált 2,57-es Sharpe-mutatóval. A GBPUSD és AUDUSD esetében a kép vegyesebb, de a passzív megközelítés ott is gyengébben teljesített. A 2022-es év során a gépi tanulásra épülő prediktív stratégiák megerősítették létjogosultságukat, különösen a válságjellegű, szélsőséges piaci helyzetek kezelésében. A részvénypiacokon, kriptovalutáknál, nemesfémeknél és több devizapáron is képesek voltak a veszteségeket csökkenteni, sőt sok esetben pozitív hozamot biztosítani. A Sharpe-mutatók javulása egyértelműen mutatja, hogy ezek a modellek hatékonyabban kezelik a kockázatot. Az olajpiac azonban továbbra is kritikus pontnak tekinthető, mivel a prediktív modellekre

épülő befektetési módszertanok rendre alulteljesítettek ezen az eszközosztályon.



5. ábra: A 4 kereskedési stratégia összehasonlítása az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés


A három vizsgált év során általánosan megfigyelhető, hogy a gépi tanuláson alapuló aktív stratégiák szisztematikusan túlteljesítették a buy-and-hold megközelítést, mind hozam, mind kockázat/hozam arány szempontjából. Ez a tendencia különösen a részvényt piacokon és a kriptovaluták piacán volt jellemző. A legnagyobb különbségek azokban az években jelentkeztek, amikor a piac volatilis volt (pl. 2020, 2022), ami alátámasztja, hogy a gépi tanulási stratégiák hatékonyabban tudják kezelni a turbulens környezetet. Kiemelkedően fontos kivétel azonban a nyersolaj, amely minden évben gyenge eredményeket hozott az aktív stratégiáknál. Ennek oka lehet az árupiaci sajátosságokban, a fundamentális események (geopolitika, OPEC-döntések) nehezen előrejelezhető hatásaiban, valamint abban, hogy az olaj

ármozgása gyakran hirtelen, szűk időablakokban történik meg. Összességében tehát a gépi tanulási stratégiák széles körű alkalmazása sikeresnek mondható, de bizonyos eszközosztályok (olaj) esetén szükség lehet a modellek továbbfejlesztésére vagy kombinálására más prediktív eszközökkel. Mindezek alapján a prediktív modellek alkalmazása értékes kiegészítője lehet a befektetési döntéseknek, de nem helyettesítik a körültekintő piaci értelmezést. Ez rámutat arra, hogy bár a mesterséges intelligencia nagy potenciált rejt magában, egyik modell sem univerzális megoldás minden piaci szituációra.

Az egyedi eszközök teljesítményértékelésén túlmenően különböző súlyozású portfóliókkal is kísérleteztem, melynek a bemutatását az alábbiakban részletezem.

A 6. ábra a 2018-as évre mutatja a négy különböző eszközosztályra épülő, azonos eszközszúlyozású portfóliók (1/3-os súllyal szerepel minden eszköz) kumulált hozamát stratégiák szerinti bontásban. A buy-and-hold megközelítés minden portfólió esetén alulteljesít, különösen a kriptovaluták esetében, ahol drasztikus, -75,13%-os veszteség figyelhető meg. Ezzel szemben az Alapstratégia jelentősen javítja a teljesítményt, különösen a kriptovaluta-portfóliónál, ahol 100,54%-os kumulált hozamot ér el, vagyis teljes mértékben felülmúlja a passzív befektetési megközelítést. A MAPE-szűrőre és MAPE-pozícióra épített modellek stabilabb, konzervatívabb eredményeket mutatnak: az árupiaci portfóliónál például mindkettő 12% körüli hozamot produkál, felülmúlva a buy-and-hold-ot. A részvénypiac és a devizapiac esetén is érzékelhető javulás tapasztalható az aktív stratégiákkal, különösen a MAPE-alapú megközelítések révén. A kriptovaluta-portfólió esetében a MAPE-szűrő visszafogottabb, de még így is pozitív teljesítményt nyújt (15,21%), míg a MAPE-pozíciós stratégia 89,91%-ot ér el, ami kiemelkedő eredmény egy ilyen extrém volatilitású környezetben. Összességében az aktív, predikció

alapú hatékonyan képesek kezelni a magas kockázatú piaci körülményeket (kriptovaluták), míg a konzervatívabb eszközosztályoknál is mérsékelt hozamjavulás érhető el.




6. ábra: Azonos súlyozású termékcsoportonkénti portfóliók kumulált féléves hozam a nyugalmi időszakra vonatkozóan (2018)

Forrás: saját szerkesztés

A 7. ábra a 2020-as év különféle portfóliókra vonatkozó kumulált hozamait tartalmazza. Megfigyelhető, hogy jelentős eltéréseket mutatkoznak a különböző eszközosztályok és stratégiák mentén. A részvénytőke portfólió esetében a buy-and-hold stratégia negatív eredményt hozott (-7,51%), míg az Alapstratégia és a MAPE-pozíció jelentős pozitív teljesítményt mutatott (37,74% és 36,90%), jelezve, hogy az aktív, predikcióalapú megközelítések válságos környezetben is képesek felülteljesíteni. Az árupiaci portfóliónál ugyan a buy-and-hold stratégia hozama pozitív volt (11,17%), az Alap- és MAPE-pozíció stratégiák eredményei negatívak lettek (-2,11% és -1,92%), ami arra utalhat, hogy ezek az aktív modellek nem tudtak jól alkalmazkodni a

piaci dinamikákhoz ebben a szegmensben. A kriptovaluta-portfólió minden stratégia szerint kiemelkedő hozamot produkált különösen az Alapstratégia (120,96%) és a MAPE-pozíció (107,37%) ért el rendkívüli teljesítményt, felülmúlva a buy-and-hold-ot is (27,43%). A devizapiacon a hozamok alacsonyok maradtak minden megközelítés esetében, de a predikciós alapú stratégiák itt is jobb eredményt értek el, mint a passzív buy-and-hold. Összességében a gépi tanuláson alapuló stratégiák különösen a magas volatilitású piacokon (kriptovaluták, részvények) tudtak kiemelkedő teljesítményt nyújtani, míg a stabilabb vagy kiszámíthatatlanabb piacokon (árupiac, deviza) a teljesítményük mérsékeltebb vagy esetenként alulteljesítő volt.




7. ábra: Azonos súlyozású termékcsoportonkénti portfóliók kumulált féléves hozam a Covid19 időszakra vonatkozóan (2020)

Forrás: saját szerkesztés

A 2022-es év adatai alapján (8. ábra) a buy-and-hold stratégia minden portfólió esetében gyenge teljesítményt mutatott, különösen a kriptovaluta

portfóliónál, ahol extrém mértékű, -103,05%-os kumulált veszteség jelentkezett. Ezzel szemben az Alapstratégia minden esetben felülteljesítette a passzív megközelítést, különösen a részvényt piacon (13,05%) és a kriptopiacaon (24,23%), ahol a volatilitás ellenére is sikerült pozitív hozamot elérni. A MAPE-szűrő stratégia stabilabb, mérsékeltebb eredményeket mutat ugyanis a részvények és az áru piaci eszközök esetében is 10% feletti hozamot biztosított, míg a kriptovalutáknál kismértékű negatív hozammal zárt (-1,67%). A MAPE-pozíció stratégia szintén kiemelkedő volt a részvény- (12,29%) és kriptovaluta-portfólióban (21,99%) megerősítve, hogy az előrejelzési hibákra alapozott pozíciókezelés hatékonyan képes csökkenteni a kockázatot turbulens piaci környezetben. Az áru piaci portfólió esetében ugyanakkor mind az Alap-, mind a MAPE-pozíciós stratégia enyhe veszteséget mutatott, ami azt jelezheti, hogy az adott piaci mozgásokat ezek a modellek kevésbé tudták jól követni. A devizapiac esetében minden megközelítés közel azonos és szerény pozitív hozamot eredményezett (kb. 1,4-2,1%), ami az alacsony volatilitásra és kisebb előrejelezhetőségi potenciálra utalhat. Összességében az aktív, predikciós alapú stratégiák 2022-ben is felülteljesítették a buy-and-hold megközelítést, különösen a részvény- és kriptopiacaon, még extrém piaci stresszhelyzetek közepette is.




8. ábra: Azonos súlyozású termékcsoportonkénti portfóliók kumulált féléves hozam az orosz-ukrán konfliktus időszakára vonatkozóan (2022)

Forrás: saját szerkesztés

A 9. ábra azonos súlyozású portfóliók (minden termék 1/12-es súllyal szerepel) kumulált hozamát mutatja három különböző évben, négyféle stratégiai megközelítés szerint. A buy-and-hold stratégia, 2018-ban és 2022-ben jelentős veszteséget mutatott (-19,86%, illetve -30,70%), míg 2020-ban mérsékelt 7,12%-os hozamot ért el. Ezzel szemben az Alapstratégia minden vizsgált évben pozitív kumulált hozamot generált, kiemelkedően 2020-ban (39,75%) és 2018-ban is erőteljesen felülteljesítve a buy-and-hold-ot (29,52%). A MAPE-szűrőre épülő stratégiától visszafogottabb, de jellemzően stabilabb eredményeket láthatunk. 2018-ban 8,98%, 2020-ban 20,52%, míg 2022-ben 5,26%-os pozitív hozammal zárt. A MAPE-pozíció megközelítés teljesítménye szintén szignifikánsan jobb, mint a passzív stratégia, különösen 2020-ban és 2018-ban, amikor +36,17%, illetve +27,60%-os kumulált hozamot ért el. Mindez arra utal, hogy az előrejelzési hibákra (MAPE) épített

szűrés és pozíciókezelés segíthet csökkenteni a negatív piaci hatásokat, illetve növeli a teljesítmény stabilitását a változó környezeti feltételek mellett.



9. ábra: A 12 termékből kialakított azonos súlyozású portfóliók féléves kumulált hozama a nyugalmi, a Covid19 és az orosz-ukrán konfliktus időszakára vonatkozóan (2018, 2020 és 2022)

Forrás: saját szerkesztés

5. KÖVETKEZTETÉSEK ÉS JAVASLATOK

A kutatás célja az volt, hogy feltárja a gépi tanulási algoritmusok, különösen a mély neurális hálózatok alkalmazhatóságát pénzügyi eszközök árfolyamainak előrejelzésére, különböző piaci környezetekben és terméktípusokon. A vizsgálat a predikciós modellek volatilitásérzékenységére, az előrejelzések megbízhatóságára és azok gyakorlati felhasználhatóságára fókuszált. A dolgozat alapvetően két fő célkitűzés alapján vizsgálta a témakört. Az első az előrejelző modellek teljesítménye és a piaci volatilitása közötti összefüggéseire, valamint az egyes modellek különböző gazdasági ciklusokban való alkalmazhatóságára fókuszál. A második célkitűzés pedig a gépi tanulási modellek által támogatott kereskedési stratégiák gyakorlati teljesítményére helyezi a hangsúlyt. Az elemzés során külön figyelmet kapott a részvényindexek, árupiaci termékek, kriptovaluták és devizapárok modellezése, mivel ezek volatilitása, likviditása és szabályozottsága nagymértékben eltér. A kutatás során végzett empirikus elemzések alapján több szempontból is megalapozott következtetések vonhatók le, melyet az alábbiakban részletezek.

C1: A kutatásom első célkitűzése annak meghatározása, hogy a különböző neurális mély tanulási modellek milyen mértékben általánosíthatóak, azaz képesek-e különböző válsághelyzetekben is kimagasló prediktív teljesítmény elérésére.

K1: Milyen kapcsolat mutatható ki a pénzügyi eszközök volatilitása és az árfolyamelőrejelzési modellek prediktív teljesítménye között?

A regressziós modellek alapján egyértelműen kimutatható, hogy a volatilitás, jelen esetben a trend és szezonálismentes (CV_STL) relatív szórás szignifikáns, pozitív kapcsolatban áll az előrejelzési hibával (MAPE). Eredményeim szerint minden vizsgált modellkategória esetén romlik az

előrejelzési pontosság, ahogy nő a piaci volatilitás, amely különösen szembetűnő a kriptovaluták esetén, de megfigyelhető az árupiaci termékeknél is. Ezzel összhangban áll több tanulmány megállapítása is, amelyek hangsúlyozzák a nemlineáris és nem stacionárius adatok előrejelzésének nehézségeit (Ouyang et al., 2021; Zhang et al., 2023; Avinash et al., 2024). A mélytanulás e kihívásokat részben képes kezelni, de a turbulens piacokon tapasztalható hirtelen elmozdulások továbbra is problémát jelentenek a predikciós megbízhatóság szempontjából.

K2: Milyen előrejelzési torzulásokat okoznak a válságidőszakokban megfigyelhető szélsőséges árfolyammozgások és hogyan reagálnak erre különböző típusú algoritmusok?

A 2020-as és 2022-es válságidőszakok jól demonstrálták, hogy a modellek teljesítménye eltérően reagál az extrém árfolyammozgásokra. A GRU modellek például meglepően stabilnak bizonyultak, míg az RNN-t tartalmazó hibrid architektúrák (pl. RNN-LSTM) teljesítménye érdemben romlott, tehát a válságidőszakok nemcsak a predikciós hiba növekedését, hanem a modellek közötti teljesítménykülönbségek erősödését is okozták. Ez megerősíti a szakirodalomból ismert megállapításokat, miszerint a túl komplex modellek nagyobb mértékben ki vannak téve az instabilitásnak (Livieris et al., 2020), illetve arra is rávilágít, hogy az előrejelző algoritmusok a fejlettségi szinttől függetlenül is érzékenyek a piaci sokkok okozta szélsőséges árfolyammozgásokra, ezért kiemelt fontossággal bír ezen tényezők figyelembevétele az előrejelző módszerek fejlesztése során (Mari és Mari, 2023 és 2025; Sivakumar, 2025).

K3: Milyen szerepet játszik a hibrid modellek architektúrája a prediktív teljesítmény változásában volatilis piaci környezetben?

A dolgozat eredményei alapján megállapítható, hogy a prediktív modellek architektúrája, különösen a hibrid mélytanulási struktúrák, jelentős szerepet játszik az előrejelzési teljesítmény alakulásában, különösen volatilis piaci környezetben. Az empirikus vizsgálatok azt mutatták, hogy az olyan modellek, amelyek első réteggként RNN-komponenst használnak, gyakran gyengébben teljesítettek a többi architektúrához képest különösen a kriptovaluták esetében. Ez az eredmény részben összhangban van Liang et al. (2022) és Ouyang et al. (2021) megállapításaival, akik arra hívták fel a figyelmet, hogy a bonyolultabb, Attention-alapú vagy Transformer-típusú architektúrák robusztusabb teljesítményt nyújthatnak extrém piaci környezetekben. Ugyanakkor a disszertációban vizsgált egyszerűbb LSTM- vagy GRU-alapú modellek több esetben is stabilabbnak bizonyultak az RNN-modulokkal szemben, különösen hibrid felépítés esetén, ami alátámasztja a hibrid architektúrák finomhangolásának fontosságát. A modellek belső szerkezete tehát nem csupán technikai preferencia kérdése, hanem a volatilitás kezelésének kulcsfontosságú eleme.

C2: A dolgozatom második célkitűzése annak a vizsgálata, hogy a gépi tanulási modellek milyen mértékben képesek javítani a pénzügyi eszközök kereskedési teljesítményét a hagyományos buy-and-hold stratégiához képest.

K4: Mennyiben képesek a gépi tanulási előrejelzéseken alapuló kereskedési stratégiák kihasználni a piaci anomáliákat, a hatékony piacok elméletével szemben?

A szabályalapú, predikcióvezérelt kereskedési stratégiák visszatesztelése igazolta, hogy több időszakban és terméktípus esetén is meghaladták a buy-and-hold referenciahozamot. A MAPE-szűrővel ellátott változatok további kockázatkezelést tettek lehetővé, mivel képesek voltak kiszűrni az alacsony

predikciós biztonságú pozíciókat. Eredményeim megerősítik Viéitez et al. (2024) és Ju et al. (2024) megállapításait, akik szerint a modellek predikciós képességein túl azok adaptív használata, például pozíciószűrés formájában, nagymértékben javítja a gyakorlati teljesítményt. A Sharpe-mutató esetében megfigyelhető volt, hogy a prediktív stratégia általában magasabb értéket mutatott, ami a hozam volatilitására vetített jobb kockázat-hozam arányt jelez. Ez a megállapítás szembe megy a hatékony piacok elméletének (EMH) azon tételével, miszerint hosszú távon nem lehet szisztematikusan meghaladni a piacot minden elérhető információ figyelembevételével (Fama, 1970).

K5: Milyen hatása van a különböző termékosztályok (pl. részvények, kriptovaluták, árupiac, devizapárok) volatilitásának a gépi tanulás által támogatott kereskedési stratégiák teljesítményére?

Eredmények szerint a kriptovaluták kiszámíthatatlansága és a devizapárok stabilitása markánsan eltér, ami közvetlen hatással van a kereskedési eredményekre. A termékspecifikus elemzések tehát rávilágítottak arra, hogy a volatilitás különböző módon hat a stratégiák teljesítményére. A kriptovaluták esetében a MAPE-szűrő különösen hatékony volt a veszteségek csökkentésében, míg a devizapiacokon az Alapstratégia stabilitása volt kiemelkedő. A részvénypiacokon a stratégiák egymáshoz viszonyított teljesítménye inkább időszakfüggőnek bizonyult, amely összhangban van a szakirodalom megállapításaival, miszerint az eszközszer specifikus volatilitás eltérő modellezési megközelítést kíván (Yu et al., 2023; Aydogan-Kilic és Selcuk-Kestel, 2023). Az eredmények alátámasztják, hogy termékspecifikus paraméterezés szükséges a maximális hatékonyság eléréséhez. Egy további fontos következtetés, hogy az azonos súlyozású portfóliók esetében a predikcióvezérelt stratégiák teljesítménye nem minden piaci szegmensben volt egységes. Az árupiaci és devizapiaci eszközök esetében kisebb volt az eltérés a stratégiai variánsok között, míg a kriptovalutákban drasztikus

különbségek mutatkoztak. Ez ismételten megerősíti, hogy a stratégia és modell hatékonysága csak adott terméktípus és időszak viszonylatában értelmezhető, így a modellválasztásnak és a paraméterhangolásnak döntő szerepe van a gyakorlati eredményességben.

K6: Milyen eltérések tapasztalhatók a gépi tanuláson alapuló stratégiák teljesítményében különböző gazdasági ciklusok alatt?

A kereskedési stratégiák teljesítménye jelentős eltérések mutatkoztak különböző piaci környezetekben. A 2018-as nyugodt piaci környezetben szinte minden modell alapú stratégia stabil nyereséget hozott. Ezzel szemben 2020-ban és 2022-ben a predikciós teljesítmény visszaesett a volatilitás erősödése miatt. Azonban MAPE-szűrős rendszerek csökkentették a veszteségek kockázatát, ami megerősíti Ouyang et al. (2021) figyelemalapú volatilitáskezelési stratégiáinak gyakorlati relevanciáját és kiemeli az adaptív döntési mechanizmusok fontosságát. Ezek a megállapítások megerősítik azt a szakirodalmi álláspontot (Kang et al., 2025), miszerint a predikciós rendszereknek alkalmazkodniuk kell a gazdasági rezsimek változásaihoz. A stratégiák teljesítménye így nemcsak a modell pontosságától, hanem annak volatilitásérzékeny alkalmazásától is függ. A kutatás egyik legfontosabb következtetése tehát az, hogy a gépi tanulási alapú kereskedési rendszerek csak akkor tudnak stabil teljesítményt nyújtani válsághelyzetekben, ha beépített predikciós validációs mechanizmusokkal és adaptív szűréssel is rendelkeznek.

A disszertáció empirikus eredményei alátámasztják, hogy a gépi tanulási modellek hatékony predikciós eszközt jelentenek, de teljesítményük szignifikánsan függ a volatilitástól, a piaci rezsimtől és az eszköz típusától. A predikciókra épülő stratégiák alkalmazása során elért többlethozam és kockázatsökkentés bizonyítja, hogy az ilyen rendszerek értékes kiegészítői

lehetnek a befektetési döntéstámogatásnak, mivel nemcsak elméleti, hanem gyakorlati előnnyel is bírnak, feltéve, hogy megfelelően integrálják az előrejelzési bizonytalanság mérését és a piac volatilitásához való alkalmazkodást.

6. ÚJ TUDOMÁNYOS EREDMÉNYEK

- I. **Igazoltam több különböző terméktípus együttes vizsgálatával (részvények, árupiaci eszközök, devizapárok, kriptovaluták), hogy a volatilitás jelentős hatással van a neurális hálózati modellek előrejelzési teljesítményére (MAPE) függetlenül az alkalmazott módszertantól.**

A kutatás során különböző eszközosztályokat (részvényindexek, árupiaci termékek, devizapárok és kriptovaluták) vizsgáltam meg három különböző időszakban. Az eredmények alapján minden esetben szignifikáns, pozitív kapcsolat mutatkozott a trend- és szezonálismentesített relatív volatilitás és az előrejelzési hiba (MAPE) között. A panel regressziós modellek magas R^2 értékeket mutattak, ami alátámasztja, hogy a volatilitás nemcsak statisztikailag szignifikáns, hanem magyarázó ereje is erős a predikciós teljesítmény változásában. Ez a hatás független volt az eszközosztály típusától és a választott modellarchitektúrától is, vagyis a volatilitás minden esetben torzító tényezőként lép fel.

- II. **Empirikus eszközökkel igazoltam, hogy a piaci volatilitás szintje befolyásolja a modellek közötti teljesítménykülönbséget, mely a magas volatilitású időszakokban érzékelhető.**

A 2018-as (nyugalmi) időszak során az egyes modellek előrejelzési hibái közel azonos tartományban mozogtak. A legtöbb modell (RNN, LSTM, GRU és ezek hibridjei) hasonló MAPE értéket produkált, így a modellválasztás nem volt meghatározó. Az alacsonyabb volatilitású időszakokban a modellek teljesítménye konvergált egymáshoz, csökkentve a modellválasztás jelentőségét. Ezzel szemben a 2020-as válságidőszakban jelentősen megnöttek a modellek közötti különbségek:

a predikciós hibák szórása több mint kétszeresére emelkedett. A vizsgálatokból az is kiderült, hogy a magasabb volatilitás szinttel nemcsak a MAPE nő, hanem a teljesítménybeli szórás is, ami különösen fontos tényező a modellalkalmazás során.

III. A vizsgált időszakokban a hibrid modellek esetén az első rejtett rétegben alkalmazott RNN architektúra teljesítményrontó hatással bír, függetlenül attól, hogy milyen másik algoritmussal van kombinálva.

A 2018-as időszak regressziós eredményei alapján egyértelműen kimutatható, hogy az RNN-re épülő hibrid modellek (RNN-GRU vagy RNN-LSTM) magasabb volatilitásérzékenységgel és alacsonyabb predikciós teljesítménnyel jellemezhetők, mint azok a hibrid modellek, amelyek nem tartalmaznak RNN komponenst az első rétegben. Ez arra utal, hogy az RNN struktúrák nehezebben kezelik a sűrűn zajos, trendfüggő idősorokat, különösen magas volatilitás esetén. Az eredmények továbbá azt mutatják, hogy nem minden modellkombináció jár teljesítménynövekedéssel és a hálózat belső szerkezete különösen az első rétegek felépítése kritikus szerepet játszik a predikciós pontosságban.

IV. Igazoltam, hogy a vizsgált időszakban a GRU-alapú előrejelző modellek kisebb mértékben érzékenyek a relatív volatilitás növekedésére, mint az RNN- vagy LSTM-alapú architektúrák, ami újszerű megközelítést nyújt a modellspecifikáció és piaci bizonytalanság kapcsolatának vizsgálatában.

A disszertációban bemutatott panel regressziós elemzések alapján a relatív volatilitás szignifikáns pozitív kapcsolatban állt az előrejelzési hibával (MAPE), függetlenül az időszaktól és az eszközosztálytól. Ugyanakkor azt is megállapítottam, hogy a volatilitásra adott

modellreakció nem egységes: az architektúrák eltérő módon és mértékben torzultak a fokozott piaci bizonytalanság hatására. A GRU-alapú modellek kisebb érzékenységet mutattak, míg az RNN-tartalmú hibrid architektúrák teljesítménye kifejezetten romlott magas volatilitás esetén. Ez az eredmény újszerű módon kombinálja a volatilitási környezet kvantitatív hatását a modellspecifikáció minőségével, és alátámasztja, hogy a predikciós kockázat nemcsak a piac aktuális állapotától, hanem a választott modellstruktúrától is függ. Ezzel lehetővé válik a modellek volatilitásérzékenységi profiljának előzetes elemzése, ami fontos gyakorlati iránymutatás lehet például prediktív kereskedési rendszerek alkalmazásánál. Ez a megállapítás illeszkedik, de tovább is fejleszti a jelenlegi szakirodalom következtetéseit, amelyek külön tárgyalják a volatilitás és modellel való interakciót, de nem vetik össze szisztematikusan különböző architektúrák volatilitás-érzékenységét.

- V. **Igazoltam, hogy a predikciós hiba (MAPE) dinamikus figyelembevételével kialakított kereskedési szabályok (pozíciónyitás időzítés és a pozícióméretezés) szignifikánsan javítják a kockázathozam arányt, különösen a magas volatilitású eszközosztályok esetében. Ez az eredmény empirikus bizonyítékkal szolgál a hatékony piacok hipotézisének gyenge formájának érvényességével szemben.**

A kutatás során a kereskedési stratégiák nem csupán a modell által előrejelzett ármozgás irányára épültek, hanem integrálták a becsült előrejelzési hibát (MAPE) is. Ez lehetővé tette, hogy a stratégia két szinten kezelje a bizonytalanságot. Egyrészt kizárta a pozíciónyitást olyan periódusokban, amikor a predikciók megbízhatósága alacsony volt. Másrészt a pozícióméretek dinamikus skálázásával közvetlenül a tőkekitettségek szintjén is alkalmazkodott a modellek teljesítményéhez. Az eredmények különösen markánsak voltak a kriptovalutáknál, ugyanis a

Litecoin és Ethereum esetében a maximális drawdown érdemben csökkent, miközben a kumulált hozam és a Sharpe-mutató jelentősen emelkedett a hagyományos buy-and-hold stratégiához képest. Ez a megközelítés új perspektívát kínál a prediktív modellek felhasználásában, mivel nemcsak determinisztikus jeleket használ a kereskedési döntésekhez, hanem a modellek bizonytalanságát is explicit módon beépíti a döntéshozatalba. Ezzel hozzájárul egy adaptív, önreflexióra képes kereskedési architektúra kialakításához, amely érzékenyen reagál a piaci rezsimek változásaira. A gyakorlatban elért teljesítmény pedig arra utal, hogy a predikciós hibák figyelembevétele révén a piac egyes szegmenseiben – különösen a magas volatilitású és információs aszimmetriával jellemezhető eszközosztályoknál – a gyenge formájú hatékony piacok hipotézisével szemben is lehetséges statisztikailag szignifikáns többlethozamot realizálni.

7. ÖSSZEFOGLALÁS

Az összetett és nagyméretű adathalmazok megjelenése jelentős technológiai és szemléletbeli változásokat okozott az előrejelzési modellek fejlesztésében és alkalmazásában, ami az elmúlt 20 évet illeti. A rengeteg adat feldolgozása már nem lenne hatékony a hagyományos módszerekkel, ezért a gépi tanulás elengedhetetlen részévé vált a legtöbb prediktív modellezéssel foglalkozó iparágnak. Különösen igaz ez a pénzügyi szektorra, ahol a profitábilis működés érdekében igyekeznek a rendelkezésre álló innovatív eszközöket a lehető legjobban kihasználni, amelyekre nagy szükség van a nem lineáris összefüggések és mintázatok feltárásához.

A disszertáció két kiemelkedően aktuális és gyakorlati szempontból is jelentős pénzügyi predikciós modellezési problémát vizsgált. Az első célkitűzés a volatilitás predikciós teljesítményre gyakorolt hatásának feltérképezése volt, míg a második a gépi tanuláson alapuló előrejelzéseket hasznosító kereskedési stratégiák hatékonyságát értékelte különböző piaci környezetekben. A kutatás egyaránt támaszkodott kvantitatív regressziós elemzésekre, mélytanulási architektúrák összehasonlítására és visszatesztelt kereskedési stratégiákra, így a disszertáció mind elméleti, mind alkalmazott aspektusokban új tudományos ismeretekkel járult hozzá a pénzügyi gépi tanulási kutatásokhoz. A bevezetésben ismertettem a terület közgazdasági háttérét és jelentőségét, valamint kitértem arra is, hogy milyen fejlődési utat jártak be a prediktív algoritmusok. Továbbá betekintést nyújtottam abba, hogy jelenleg hol tart ez a tudományág és melyek a legújabb trendek. Az általam vizsgált témakör meglehetősen népszerűnek számít a nemzetközi kutatók körében és rengeteg publikáció közül válogathatunk, hogy minél részletesebb képet kaphassunk. A szisztematikus szakirodalmi áttekintést négy fő részre osztottam, amelyekben részletesen foglalkoztam a részvény-, kriptovaluta-, áru- és devizapiacokkal

egyaránt. A tudományos publikációk feldolgozása iránymutatással szolgált egyrészt a modellek sajátosságainak megismerésében és megértésében, másrészt a különböző termékspecifikus tényezők azonosításában is. A kutatásom empirikus részében a legnagyobb forgalmú részvényindexek (S&P500, DAX, Nikkei225), áruipiaci termékek (nyersolaj - Crude, arany, ezüst), kriptovaluták (Bitcoin, Ethereum, Litecoin) és devizapárok (EUR/USD, GBP/USD, AUD/USD) adatait használtam fel a 2016. január 1. és 2022. június 30. időszakra vonatkozóan. Részben azért erre a periódusra esett a választás, mert itt megtalálható a nyugalmi időszak (2018), a Covid19 (2020) és a háborús krízis (2022) egyaránt, részben pedig azért, mert a kriptovaluták relatíve új terméknek számítanak a többihez képest, így az árfolyamadataik is kisebb időszakot ölelnek fel. Az összehasonlíthatóság szempontjából tehát ez tűnt optimális döntésnek. Az adatokat a www.finance.yahoo.com weboldalról gyűjtöttem össze, kivételt képeznek a kriptovaluták, mert ezek adatai a www.coinmarketcap.com oldalról származnak. A modellezés alapját három mély tanulási algoritmus képezte (RNN, LSTM, GRU), továbbá az ezekből kialakított szintén három hibrid módszertan (LSTM-GRU, RNN-LSTM, RNN-GRU). A valós és becsült árfolyamok közötti eltéréseket pedig a MAPE mutató segítségével prezentáltam. Az eredmények fejezetet alapvetően három fő részre bontottam. Az elsőben a vizsgált modellek terméktípusonkénti, modellenkénti és időszakonkénti összehasonlítását végeztem el. A módszerek teljesítményelemzése ugyanis nélkülözhetetlen volt a további vizsgálatokhoz, amely a volatilitásra és a valós kereskedési stratégiákra irányult. A dolgozat első célkitűzése annak az összefüggésnek a feltárására irányult a pénzügyi eszközök eltérő volatilitási szerkezete befolyásolja az idősor-alapú gépi tanulási modellek pontosságát. A különböző termékosztályokon (részvények, áruipiaci eszközök, kriptovaluták és devizapárok) végzett kísérletek

megegerősítették, hogy a relatív volatilitás és a predikciós hiba között szoros, pozitív irányú kapcsolat mutatható ki, melyet a különböző architektúrákra futtatott regressziós modellek szignifikánsan alátámasztottak. A kapcsolat minden vizsgált időszakban fennállt, de különösen erősnek bizonyult a 2020-as és 2022-es, válsághelyzetekkel jellemezhető periódusokban. A kutatás másik fontos megállapítása, hogy a modellek teljesítménye erősen időszak- és eszközfüggő. A nyugalmi periódusban (2018) a különbségek minimalizálódtak, míg a válságidőszakokban (2020, 2022) a modellválasztás kritikus tényezővé vált. A hibrid architektúrák (RNN-GRU, LSTM-GRU) a legtöbb esetben jobban teljesítettek, de nem minden kombináció volt előnyös, különösen az RNN első réteggként való használata rontotta a teljesítményt. A kutatás így közvetlenül igazolta azt a feltételezést, hogy sem a volatilitás, sem a modell architektúra nem kezelhető független tényezőként a predikciós teljesítmény vizsgálata során. A kutatás második célkitűzése annak vizsgálata volt, hogy a gépi tanulási modellekre épített kereskedési stratégiák képesek-e szisztematikusan felülteljesíteni a passzív befektetési megközelítést (buy-and-hold), különösen eltérő volatilitási környezetben. A dolgozat visszatesztelt stratégiákat vizsgált egyenlő súlyozású portfóliókban, három év során (2018, 2020, 2022) és négy különböző eszközosztályon keresztül. A gépi tanulási modellek előrejelzési teljesítményére alapozott módszerek (Alapstratégia, MAPE-szűrő és MAPE-pozíció) konzisztensen javították a hozam és kockázat arányát, amely leginkább a Sharpe-mutató és a drawdown alacsonyabb értékeiben mutatkozott meg. A kriptovaluták esetében a gépi tanulásra épülő stratégiák 2022-ben voltak a legkiemelkedőbbek, miközben a veszteségek jelentősen mérséklődtek. A 2.8 szakirodalmi alfejezetében ismertetett kereskedési stratégiai irodalommal összhangban a dolgozat eredményei azt mutatják, hogy a gépi tanulás nemcsak előrejelzési pontosságot kínál, hanem döntéstámogatási potenciált is hordoz. A különbség ott mutatkozik, hogy a

jelen kutatás a stratégiák volatilitás-érzékenységet is explicit módon számszerűsítette, ami új szempontot ad a gépi tanulás alkalmazhatóságának értékeléséhez befektetési környezetben. A stratégiák sikeressége megkérdőjelezi a hatékony piacok elméletének (EMH) gyakorlati érvényességét, különösen, ha az alkalmazott modellek képesek adaptálódni a piaci rezsimekhez, amit jelen kutatás több ízben bizonyított.

Összességében a dolgozat eredményei hozzájárulnak a gépi tanulási modellek volatilitásérzékenységének megértéséhez és alátámasztják, hogy a prediktív teljesítmény nemcsak a modell struktúrájától, hanem a piaci környezet jellemzőitől is nagymértékben függ. A szakirodalmi háttér alapján kijelenthető, hogy bár számos publikáció foglalkozik a volatilitás előrejelzésével, kevés kutatás elemzi kifejezetten a volatilitás hatását a predikciós teljesítményre, különösen többféle eszközosztályt egyidejűleg vizsgálva. Az előrejelző modellekre alapozott kereskedési stratégiák vizsgálata pedig tovább erősíti a dolgozat gazdasági gyakorlati értékét. A kutatás felhívja a figyelmet a gépi tanulás pénzügyi területen történő felhasználhatóságának sokszínűségére és kiváló eredményeire, valamint hangsúlyozza, hogy a legújabb technológiák alkalmazása elengedhetetlen a folyamatos fejlődés és a rentábilis működés miatt.

8. FELHASZNÁLT SZAKIRODALOM

1. Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques–Part II: Soft computing methods. *Expert Systems with applications*, 36(3), 5932-5941. doi: <https://doi.org/10.1016/j.eswa.2008.07.006>
2. Avinash, G., Ramasubramanian, V., Ray, M., Paul, R. K., Godara, S., Nayak, G. H. H., ... & Iquebal, M. A. (2024). Price Forecasting of TOP (Tomato, Onion and Potato) Commodities using Hidden Markov-based Deep Learning Approach. *Statistics and Applications*, 22(2), 1-28.
3. Aydogan-Kilic, D., & Selcuk-Kestel, A. S. (2023). Modification of hybrid RNN-HMM model in asset pricing: univariate and multivariate cases. *Applied Intelligence*, 53(20), 23812-23833. doi: <https://doi.org/10.1007/s10489-023-04762-7>
4. Bai, Y., Xie, J., Liu, C., Tao, Y., Zeng, B., & Li, C. (2021). Regression modeling for enterprise electricity consumption: A comparison of recurrent neural network and its variants. *International Journal of Electrical Power & Energy Systems*, 126, 106612. doi: <https://doi.org/10.1016/j.ijepes.2020.106612>
5. Borovkova, S., & Tsiamas, I. (2019). An ensemble of LSTM neural networks for high-frequency stock market classification. *Journal of Forecasting*. doi: <https://doi.org/10.1002/for.2585>
6. Brockwell, P. J., & Davis, R. A. (Eds.). (2002). *Introduction to time series and forecasting*. New York, NY: Springer New York.
7. Büyükaşahin, Ü. Ç., & Ertekin, Ş. (2019). Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition. *Neurocomputing*, 361, 151-163. doi: <https://doi.org/10.1016/j.neucom.2019.05.099>
8. Chen, M. Y., & Chen, B. T. (2015). A hybrid fuzzy time series model based on granular computing for stock price forecasting. *Information Sciences*, 294, 227-241. doi: <https://doi.org/10.1016/j.ins.2014.09.038>
9. Chen, Y., & Hao, Y. (2017). A feature weighted support vector machine and K-nearest neighbor algorithm for stock market indices prediction. *Expert Systems with Applications*, 80, 340-355. doi: <https://doi.org/10.1016/j.eswa.2017.02.044>

10. Cleveland, R. B., Cleveland, W. S., McRae, J. E., & Terpenning, I. (1990). STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, 6(1), 3–73.
11. Daniel, K., Hirshleifer, D., & Subrahmanyam, A. (1998). Investor Psychology and Security Market Under- and Overreactions. *The Journal of Finance*, 53(6), 1839–1885. doi: <https://doi.org/10.1111/0022-1082.00077>
12. De BOND, W. F. M., & THALER, R. (1985). Does the Stock Market Overreact? *The Journal of Finance*, 40(3), 793–805. doi: 10.1111/j.1540-6261.1985.tb05004.x
13. Duarte, J. B. D., Sarmiento, L. H. T., & Juárez, K. J. S. (2017). Evaluation of the effect of investor psychology on an artificial stock market through its degree of efficiency. *Contaduría y Administración*, 62(4), 1361-1376. doi: <https://doi.org/10.1016/j.cya.2017.06.014>
14. Efendi, R., Arbaiy, N., & Deris, M. M. (2018). A new procedure in stock market forecasting based on fuzzy random auto-regression time series model. *Information Sciences*, 441, 113-132. doi: <https://doi.org/10.1016/j.ins.2018.02.016>
15. Fama, E. F. (1965). Random Walks in Stock Market Prices. *Financial Analysts Journal*, 21(5), 55–59.
16. Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), 383. doi: <https://doi.org/10.2307/2325486>
17. Fama, E. F. (1998). Market efficiency, long-term returns, and behavioral finance. *Journal of financial economics*, 49(3), 283-306. doi: [https://doi.org/10.1016/S0304-405X\(98\)00026-9](https://doi.org/10.1016/S0304-405X(98)00026-9)
18. Faru, S. H., Waititu, A., & Nderu, L. (2023). A Hybrid Neural Network Model Based on Transfer Learning for Forecasting Forex Market. *Journal of Data Analysis and Information Processing*, 11(2), 103-120. doi: 10.4236/jdaip.2023.112007
19. He, H., Gao, S., Jin, T., Sato, S., & Zhang, X. (2021). A seasonal-trend decomposition-based dendritic neuron model for financial time series prediction. *Applied Soft Computing*, 108, 107488. doi: <https://doi.org/10.1016/j.asoc.2021.107488>
20. Hoseinzade, E., & Haratizadeh, S. (2019). CNNpred: CNN-based stock market prediction using a diverse set of variables. *Expert*

- Systems with Applications, 129, 273-285. doi: <https://doi.org/10.1016/j.eswa.2019.03.029>
21. Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009. doi: <https://doi.org/10.1016/j.socl.2020.100009>
 22. Ju, C., Shen, Q., & Ni, X. (2024). Leveraging LSTM Neural Networks for Stock Price Prediction and Trading Strategy Optimization in Financial Markets. *Applied and Computational Engineering*, 112, 47-53. doi: <https://doi.org/10.54254/2755-2721/2024.17906>
 23. Kang, M., Hong, J., & Kim, S. (2025). Harnessing technical indicators with deep learning based price forecasting for cryptocurrency trading. *Physica A: Statistical Mechanics and its Applications*, 130359. doi: <https://doi.org/10.1016/j.physa.2025.130359>
 24. Kim, H. Y., & Won, C. H. (2018). Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models. *Expert Systems with Applications*, 103, 25-37. doi: <https://doi.org/10.1016/j.eswa.2018.03.002>
 25. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197, 116659. doi: <https://doi.org/10.1016/j.eswa.2022.116659>
 26. Liang, Y., Lin, Y., & Lu, Q. (2022). Forecasting gold price using a novel hybrid model with ICEEMDAN and LSTM-CNN-CBAM. *Expert Systems with Applications*, 206, 117847. doi: <https://doi.org/10.1016/j.eswa.2022.117847>
 27. Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN–LSTM model for gold price time-series forecasting. *Neural Computing and Applications*. doi:10.1007/s00521-020-04867-x
 28. Lo, A. W. (2004). The Adaptive Markets Hypothesis. *The Journal of Portfolio Management*, 30(5), 15–29. doi: 10.3905/jpm.2004.442611
 29. Lohrmann, C., & Luukka, P. (2019). Classification of intraday S&P500 returns with a Random Forest. *International Journal of Forecasting*, 35(1), 390-407. Lohrmann, C., & Luukka, P. (2018). Classification of intraday S&P500 returns with a Random Forest. *International Journal of Forecasting*. doi: 10.1016/j.ijforecast.2018.08.004

30. Malkiel, B., Mullainathan, S., & Stangle, B. (2005). Market Efficiency versus Behavioral Finance. *Journal of Applied Corporate Finance*, 17(3), 124–136. doi: 10.1111/j.1745-6622.2005.00053.x
31. Maqsood, H., Mehmood, I., Maqsood, M., Yasir, M., Afzal, S., Aadil, F., ... & Muhammad, K. (2020). A local and global event sentiment based efficient stock exchange forecasting using deep learning. *International Journal of Information Management*, 50, 432-451. doi: <https://doi.org/10.1016/j.ijinfomgt.2019.07.011>
32. Mari, C., & Mari, E. (2023). Deep learning based regime-switching models of energy commodity prices. *Energy Systems*, 14(4), 913-934. doi: <https://doi.org/10.1007/s12667-022-00515-6>
33. Mari, C., & Mari, E. (2025). Stochastic DNN-based models meet hidden Markov models: A challenge on natural gas prices at the Henry Hub. *Neural Computing and Applications*, 1-20. doi: <https://doi.org/10.1007/s00521-025-11286-3>
34. Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis on the Tehran stock exchange. *IEEE Access*, 1–1. doi: 10.1109/access.2020.3015966
35. Ortu, M., Uras, N., Conversano, C., Bartolucci, S., & Destefanis, G. (2022). On technical trading and social media indicators for cryptocurrency price classification through deep learning. *Expert Systems with Applications*, 198, 116804. doi: <https://doi.org/10.1016/j.eswa.2022.116804>
36. Ouyang, Z. S., Yang, X. T., & Lai, Y. (2021). Systemic financial risk early warning of financial market in China using Attention-LSTM model. *The North American Journal of Economics and Finance*, 56, 101383. doi: <https://doi.org/10.1016/j.najef.2021.101383>
37. Patel, P. B., & Marwala, T. (2006, October). Forecasting closing price indices using neural networks. In 2006 IEEE international conference on systems, man and cybernetics (Vol. 3, pp. 2351-2356). IEEE. doi: 10.1109/ICSMC.2006.385214
38. Reston Filho, J. C., Affonso, C. D. M., & de Oliveira, R. C. (2014). Energy price prediction multi-step ahead using hybrid model in the Brazilian market. *Electric power systems research*, 117, 115-122. doi: <https://doi.org/10.1016/j.epsr.2014.08.006>

39. Sedighi, M., Jahangirnia, H., Gharakhani, M., & Farahani Fard, S. (2019). A novel hybrid model for stock price forecasting based on metaheuristics and support vector machine. *Data*, 4(2), 75. doi: <https://doi.org/10.3390/data4020075>
40. Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of economic perspectives*, 17(1), 83-104. doi: <https://doi.org/10.1257/089533003321164967>
41. Sivakumar, G. (2025). HMM-LSTM Fusion Model for Economic Forecasting. *arXiv preprint arXiv:2501.02002*. doi: <https://doi.org/10.48550/arXiv.2501.02002>
42. Song, Y., Lee, J. W., & Lee, J. (2019). A study on novel filtering and relationship between input-features and target-vectors in a deep learning model for stock price prediction. *Applied Intelligence*, 49, 897-911. doi: <https://doi.org/10.1007/s10489-018-1308-x>
43. Timmermann, A., & Granger, C. W. (2004). Efficient market hypothesis and forecasting. *International Journal of forecasting*, 20(1), 15-27. doi: [https://doi.org/10.1016/S0169-2070\(03\)00012-8](https://doi.org/10.1016/S0169-2070(03)00012-8)
44. Vidal, A., & Kristjanpoller, W. (2020). Gold volatility prediction using a CNN-LSTM approach. *Expert Systems with Applications*, 157, 113481. doi: <https://doi.org/10.1016/j.eswa.2020.113481>
45. Viéitez, A., Santos, M., & Naranjo, R. (2024). Machine learning Ethereum cryptocurrency prediction and knowledge-based investment strategies. *Knowledge-Based Systems*, 299, 112088. doi: <https://doi.org/10.1016/j.knosys.2024.112088>
46. Wei, L. Y., Chen, T. L., & Ho, T. H. (2011). A hybrid model based on adaptive-network-based fuzzy inference system to forecast Taiwan stock market. *Expert Systems with Applications*, 38(11), 13625-13631. doi: <https://doi.org/10.1016/j.eswa.2011.04.127>
47. Weng, B., Ahmed, M. A., & Megahed, F. M. (2017). Stock market one-day ahead movement prediction using disparate data sources. *Expert Systems with Applications*, 79, 153-163. doi: <https://doi.org/10.1016/j.eswa.2017.02.041>
48. Xiao, H., Chen, Z., Cao, R., Cao, Y., Zhao, L., & Zhao, Y. (2022). Prediction of shield machine posture using the GRU algorithm with adaptive boosting: A case study of Chengdu Subway project. *Transportation Geotechnics*, 37, 100837. doi: <https://doi.org/10.1016/j.trgeo.2022.100837>

49. Yeh, C. Y., Huang, C. W., & Lee, S. J. (2011). A multiple-kernel support vector regression approach for stock market price forecasting. *Expert Systems with Applications*, 38(3), 2177-2186. doi: <https://doi.org/10.1016/j.eswa.2010.08.004>
50. Yu, Y., Lin, Y., Hou, X., & Zhang, X. (2023). Novel optimization approach for realized volatility forecast of stock price index based on deep reinforcement learning model. *Expert Systems with Applications*, 120880. doi: <https://doi.org/10.1016/j.eswa.2023.120880>
51. Zhang, J., Ye, L., & Lai, Y. (2023). Stock price prediction using CNN-BiLSTM-Attention model. *Mathematics*, 11(9), 1985. doi: <https://doi.org/10.3390/math11091985>
52. Zhao, L., Li, Z., Qu, L., Zhang, J., & Teng, B. (2023). A hybrid VMD-LSTM/GRU model to predict non-stationary and irregular waves on the east coast of China. *Ocean Engineering*, 276, 114136. doi: <https://doi.org/10.1016/j.oceaneng.2023.114136>
53. Zolfaghari, M., & Gholami, S. (2021). A hybrid approach of adaptive wavelet transform, long short-term memory and ARIMA-GARCH family models for the stock index prediction. *Expert Systems with Applications*, 182, 115149. doi: <https://doi.org/10.1016/j.eswa.2021.115149>

9. A TÉMAKÖRHÖZ KAPCSOLÓDÓ PUBLIKÁCIÓK

Bareith, T., Tatay, T., & Vancsura, L. (2023). Árupiaci termékek árfolyamelőrejelzése korszerű eszközökkel átmeneti gazdasági időszakban. Előadás. XVII. Soproni Pénzügyi Napok: „A mesterséges intelligencia szerepe a fenntartható gazdasági döntésekben” pénzügyi, adózási és számviteli szakmai és tudományos konferencia. Sopron: Soproni Egyetem Lámfalussy Sándor Közgazdaságtudományi Kar, 2023. október 11-13.

Vancsura, L., Tatay, T., & Bareith, T. (2023). Evaluating the effectiveness of modern forecasting models in predicting commodity futures prices in volatile economic times. *Risks*, 11(2), 27. doi: <https://doi.org/10.3390/risks11020027>

Vancsura, L., & Bareith, T. (2023). Analysis of the performance of predictive models during Covid-19 and the Russian-Ukrainian war. *Public Finance Quarterly*= *Pénzügyi Szemle*, 69(2), 118-132. doi: https://doi.org/10.35551/PFQ_2023_2_7

Bareith, T., Tatay, T., & Vancsura, L. (2024). Navigating Inflation Challenges: AI-Based Portfolio Management Insights. *Risks*, 12(3), 46. doi: <https://doi.org/10.3390/risks12030046>

Vancsura, L., Tatay, T., & Bareith, T. (2024). Investigating the Role of Activation Functions in Predicting the Price of Cryptocurrencies during Critical Economic Periods. *Virtual Economics*, 7(4), 64–91. [https://doi.org/10.34021/ve.2024.07.04\(4\)](https://doi.org/10.34021/ve.2024.07.04(4))

Vancsura, L., Tatay, T., & Bareith, T. (2025). Navigating AI-Driven Financial Forecasting: A Systematic Review of Current Status and Critical Research Gaps. *Forecasting*, 7(3), 36. <https://doi.org/10.3390/forecast7030036>